



*Escuela Técnica Superior de Ingenieros de Caminos,
Canales y Puertos.*
UNIVERSIDAD DE CANTABRIA



Influencia de los parámetros de vía en el comportamiento de las placas de asiento: aplicación de algoritmos machine learning

Trabajo realizado por:

Jose A. Sainz-Aja Guerra

Dirigido:

Isidro A. Carrascal Vaquero

Diego Ferreño Blanco

Titulación:

**Máster Universitario en
Integridad y Durabilidad de
Materiales, Componentes y
Estructuras**

Santander, octubre de 2019

TRABAJO FIN DE MASTER

INDICE

CAPÍTULO 1 INTRODUCCIÓN Y OBJETIVOS	5
1.1 La importancia del ferrocarril en nuestros días.....	5
1.2 Importancia y variabilidad de las placas de asiento	6
1.3 Aplicabilidad de los algoritmos de machine learning	7
1.4 Diagrama de flujo	8
CAPÍTULO 2 ESTADO DEL CONOCIMIENTO.....	11
2.1 Placa de asiento	12
2.2 Modelos de machine learning	14
2.2.1 Multi linear regression (MLR)	16
2.2.2 K-Nearest Neighbor for Regression (KNN).....	17
2.2.3 Regression tree (RT).....	18
2.2.4 Random forest (RF).....	19
2.2.5 Multilayer perceptron (MLP)	20
2.2.6 Support Vector Regression (SVR)	21
CAPÍTULO 3 MATERIALES Y METODOLOGÍA EXPERIMENTAL	23
3.1 Materiales	24
3.2 Metodología experimental	24
3.2.1 Ensayos de laboratorio.....	25
3.2.1.1 Rigidez vertical estática.....	26
3.2.1.2 Rigidez vertical dinámica.....	27
3.2.2 Modelos de machine learning	30
3.2.2.1 Selección del modelo óptimo para cada material	30
3.2.2.2 Análisis de la relevancia de cada una de las variables analizadas	31
3.2.2.3 Análisis cuantitativo de la influencia de cada uno de los parámetros.....	31

CAPÍTULO 4 RESULTADOS Y ANÁLISIS DE LOS RESULTADOS	33
4.1 Ensayos de laboratorio.....	34
4.1.1 Rigidez vertical estática.....	34
4.1.2 Rigidez vertical dinámica.....	37
4.2 Modelos de machine learning	44
4.2.1 Selección del modelo óptimo para cada material	44
4.2.2 Análisis de la relevancia de cada una de las variables analizadas	48
4.2.3 Análisis cuantitativo de la influencia de cada uno de los parámetros.....	50
CAPÍTULO 5 CONCLUSIONES Y TRABAJO FUTURO.....	55
5.1 Conclusiones	56
5.1.1 Ensayos convencionales.....	56
5.1.2 Machine learning	57
5.1 Trabajo futuro	59
CAPÍTULO 6 BIBLIOGRAFÍA	61

CAPÍTULO 1

Introducción y objetivos

1.1 La importancia del ferrocarril en nuestros días

En un mundo globalizado, particulares y empresas exigen medios de transporte eficaces tanto de personas como de mercancías. Rapidez, seguridad y respeto por el medio ambiente son demandas ineludibles en la actualidad. Son varias las razones que han hecho de la alternativa ferroviaria uno de los medios de transporte más utilizados en el mundo. Las principales ventajas del ferrocarril frente a otros competidores son, entre otras, el alto nivel de seguridad y fiabilidad junto con reducidos costes e impacto medioambiental (ocupación del espacio, emisiones de gases de efecto invernadero, etc.). Según el Informe del año 2017 elaborado por el Observatorio del Transporte y la Logística en España (perteneciente al Ministerio de Fomento), el ferrocarril fue el medio de transporte

elegido para trasladar el 28.8 % de las mercancías en España durante el 2016. Dicho documento también indica que, durante ese mismo año, se realizaron más del doble de desplazamientos peninsulares de larga distancia por tren que por avión [1]. Según el informe de la comisión técnico-científica para el estudio de mejoras en el sector ferroviario, el ferrocarril se encargó del 29% del transporte público en España durante el año 2011. Por otro lado, respecto al riesgo de accidente mortal por kilómetro, los valores del ferrocarril y el avión son comparables, mientras que, por ejemplo, en el caso del transporte en vehículo privado es 28 veces mayor que en el caso del ferrocarril [2].

1.2 Importancia de las placas de asiento

Las placas de asiento son elementos de la superestructura ferroviaria que se colocan entre el carril y la traviesa o la vía en placa. Su función principal es aportar flexibilidad a la vía. Lo que la convierten en un elemento fundamental en la integridad estructural de la superestructura ferroviaria. Si las placas de asiento fuesen demasiado rígidas, la vida de los elementos que se encuentran por debajo de esta se vería reducida, ya que no sería capaz de absorber los esfuerzos que genera el paso del tren. Por su parte, si la placa de asiento fuese demasiado flexible, eso reduciría la vida útil de los elementos de la sujeción, incluida la de la propia placa de asiento, y el confort en el tren que circula por la vía.

A pesar de la gran importancia de las placas de asiento, la producción científica que analiza cómo varían las propiedades mecánicas de estas placas en función de las condiciones de uso es escasa. En este trabajo fin de master se analiza la influencia sobre el comportamiento mecánico, rigidez vertical estática y dinámica, parámetro fundamental de vía, de la temperatura de funcionamiento, la amplitud de carga (carga por eje), toe load (precarga proporcionada por la sujeción) y la frecuencia de ensayo (velocidad de paso del tren). Este análisis se realizó sobre tres de los materiales más comúnmente utilizados para la fabricación de placas de asiento como son el EPDM, TPE y EVA.

1.3 Aplicación de algoritmos de machine learning

La estado y el rendimiento a largo plazo de la infraestructura son críticos en cualquier sistema ferroviario, no sólo debido a los aspectos de seguridad, sino también debido a los altos costes de mantenimiento que implica. Además, es muy importante minimizar cualquier perturbación en el servicio ferroviario debido a las repercusiones sociales y económicas. A pesar de su importancia, la gestión del rendimiento y del mantenimiento de la vía es, científicamente, uno de los elementos menos comprendidos y menos predecibles de los sistemas ferroviarios. Para tratar de resolver este problema, el análisis de la estructura de la vía y su respuesta dinámica ha dedicado la atención de muchos investigadores que pretenden apoyar a la industria ferroviaria en su desarrollo [3–9].

Estos modelos tienen el problema de que las propiedades mecánicas de algunos elementos, como son por ejemplo las placas de asiento, son difíciles de predecir debido a que dependen de múltiples variables que, a la vez interactúan entre sí. Para poder predecir de manera precisa la rigidez de las placas de asiento en función de las condiciones de uso, en este trabajo fin de master se propone utilizar herramientas de machine learning. Estos algoritmos también permiten identificar aquellas variables que tienen una mayor repercusión sobre las propiedades que se busca predecir. Posteriormente, para poder implementar dicho modelo en un software de elementos finitos, se propone que dicho algoritmo sea capaz de estimar unas propiedades mecánicas equivalentes para ser implementados en un modelo de elementos finitos sea un modelo elástico lineal, lo que reduciría en gran medida el gasto computacional.

La caracterización precisa de los componentes de la infraestructura ferroviaria, en los que las placas de asiento tienen un papel significativo debido a su relevancia en el rendimiento global de la vía, tienen una gran importancia en los estudios de interacción vehículo-vía y abren la posibilidad de integrar modelos de contacto rueda-carril más detallados [10–16], para considerar las irregularidades de la vía [17,18] y otras singularidades de la vía [6,19–22] en los estudios destinados a evaluar el rendimiento de la vía y la evolución de la degradación [4,23–25] en condiciones de funcionamiento realistas. Más específicamente, se prevé que las propiedades de las placas de asiento aquí caracterizadas puedan integrarse en los modelos de vía en placa calibrada propuestos para construir modelos de vía realistas en varios escenarios de operación. Estos modelos fiables pueden utilizarse junto con modelos de vehículos detallados, en un entorno de simulación conjunta, para estudiar el comportamiento a largo plazo de la infraestructura ferroviaria. Este enfoque permite el desarrollo de modelos adecuados de degradación de la vía, que pueden utilizarse para fundamentar las herramientas de apoyo a la toma de decisiones, promoviendo la implementación de estrategias de mantenimiento basadas en la ciencia. Esta metodología supera las limitaciones del enfoque convencional utilizado por la industria ferroviaria, que identifica la degradación y el deterioro mediante la realización de inspecciones periódicas, que son perturbadoras y poco eficaces.

1.4 Diagrama de flujo

En la Figura 1-1 se puede ver un diagrama de flujo que resume de forma concisa el trabajo realizado en el presente trabajo fin de master.

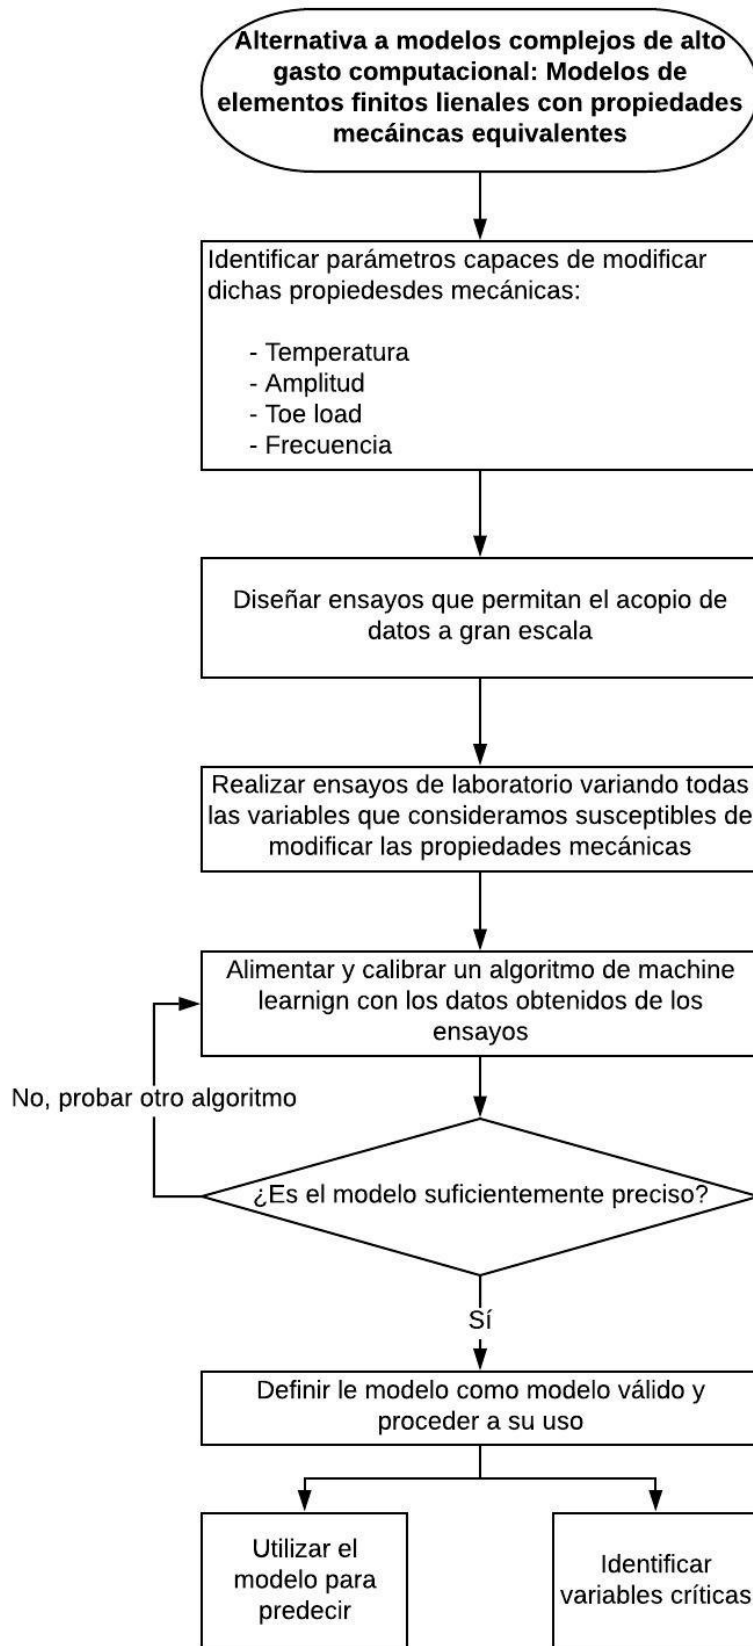


Figura 1-1: Diagrama de flujo de las actividades de investigación acometidas en el desarrollo de la presente trabajo fin de master.

CAPÍTULO 2

Estado del conocimiento

En este Capítulo, se presentan una serie de conceptos que estarán presentes a lo largo de este trabajo fin de master y que serán fundamentales para la interpretación de los resultados obtenidos en este estudio. Dichos conceptos, se referencian por medio de la recopilación de la situación actual de cada una de las diversas áreas que guardan relación con esta investigación.

Se entiende por superestructura de vía el conjunto de elementos que se encuentran situados encima de la capa de forma, integrados por las capas de asiento (subbalasto y balasto) y los elementos de la vía (traviesas, placas de asiento, carriles, sujeciones, los aparatos de vía etc.).

La rigidez vertical de la vía es una de las principales variables en el servicio y el mantenimiento de las vías ferroviarias [26–28]. En la tipología clásica de vía abalastada, esta rigidez depende, principalmente, de la rigidez de la placa de asiento, estando influenciada en segundo grado por la rigidez de la cama de balasto sobre la que descansan las traviesas. Pero la evolución de esta tipología de vía hacia la vía en placa [29], convierte de manera prácticamente absoluta, a la placa de asiento, o conjunto de ellas, en la o las encargada de aportar rigidez vertical a la vía.

2.1 Placa de asiento

Tal y como definen Sol-Sánchez et al. en su artículo “The use of elastic elements in railway tracks: A state of the art review” [30], una rigidez elevada de la placa de asiento reducirá el daño en los elementos por encima de la misma, mientras que, una placa de asiento de poca rigidez reducirá el daño en los elementos que se encuentran por debajo de esta. Esto se ve reflejado en que, al utilizar una placa de asiento de baja rigidez, se reducirá la transmisibilidad a las capas inferiores de la infraestructura, lo que, por ejemplo, reducirá el ruido y vibraciones de las traviesas. De igual manera, se atenúan más los impactos que en el caso de una placa rígida, lo que entre otras cosas reducirá el daño que sufren las traviesas. Además, tienen otras ventajas añadidas como que suaviza los cambios de rigidez en los cambios de sección, véase, entradas y salidas de puentes o túneles. Por su parte, el uso de placas de asiento rígidas tendrá una serie de ventajas como una menor deflexión de carril, esto es, un menor consumo de energía por parte de las circulaciones. También se reducirán los desplazamientos y aceleraciones del carril, aumentando la vida útil de las sujeciones y reduciendo el ruido y las vibraciones del carril [31]. Cabe destacar que, tal y como apuntan Kaewunruen et al. [32], la placa de asiento elegida puede tener una gran influencia en la frecuencia de resonancia de las traviesas, lo que puede dar lugar al fallo prematuro de las mismas. De manera general también hay que resaltar que las placas con mayor rigidez tienen generalmente una mayor vida útil.

Dada la alta importancia de estas placas de asiento, resulta fundamental una correcta caracterización mecánica de dichos elementos. Es bien sabido que las placas de asiento presentan un comportamiento altamente no lineal, lo que implica que la rigidez de la placa de asiento dependerá de las condiciones de ensayo. El hecho de que la rigidez depende de la frecuencia de ensayo es un hecho más que contrastado [33,34]. De igual manera, se sabe que el valor medio de carga también puede influir en la rigidez de la placa de asiento [35,36], al igual que la amplitud de la carga [37,38]. De la misma manera, se sabe, que la temperatura también puede influir en la rigidez de la placa de asiento [39].

En una situación típica de vía, los valores de frecuencia y de amplitud de carga dependerán, principalmente, de la velocidad y el peso del tren que circula por la misma. Por su parte, el valor medio será una combinación entre la fuerza de apriete de la sujeción y el peso del tren. Esta fuerza de apriete, en condiciones ideales, ronda los 18 kN, pero son diversos los fenómenos que pueden modificarla. Un apriete excesivo puede dar lugar a un incremento en la misma, y por su parte, una falta de apriete o un fenómeno de fluencia de la vaina, puede reducir esta carga. Así mismo, es posible que la sujeción este rota o no este montada correctamente, momento en que el toe load se reducirá a 0. Las normas UNE-EN 13481-2 [40] y UNE-EN 13146-9 [41] obligan a que la caracterización de estos materiales se realice a una temperatura de 23 ± 5 °C, siendo fácil entender que sus condiciones de uso difieren en gran medida de dichas condiciones ideales. Además, cabe destacar que, como consecuencia de la ubicación del sistema, las temperaturas tanto medias como extremas de uso pueden verse modificadas.

Kai et al. [42] analizó la influencia de la amplitud de carga en la rigidez vertical de placas de asiento de thermoplastic elastomers, TPE, obteniendo que, esta aumenta al aumentar la amplitud de carga. De igual manera, Zhu et al. apreció que al aumentar la frecuencia, aumenta la histéresis y la rigidez [37]. A. Fenander concluye que para un “rubber pad” la rigidez vertical aumenta claramente al aumentar la precarga y ligeramente al aumentar la frecuencia [33]. Kai Wei et al. [43] analiza la influencia de la frecuencia y a temperatura en la rigidez vertical de

una placa de asiento “blanda” de la sujeción WJ-8 rail, donde concluye que no solamente un incremento en la frecuencia aumenta la rigidez, una reducción en la temperatura tiene un efecto similar.

2.2 Modelos de machine learning

El aprendizaje automático o *machine learning* es una rama de la inteligencia artificial basada en la idea de que los modelos pueden aprender de datos, identificar patrones y tomar decisiones con mínima intervención humana.

Si bien el aprendizaje automático tiene un amplio rango de utilidades, este trabajo se ha centrado en un aprendizaje supervisado. En el aprendizaje supervisado, los algoritmos trabajan con datos (output data), intentado encontrar una función que, dadas las variables de entrada (input data), sea capaz de predecir un output adecuado. El algoritmo se entrena con un “histórico” de datos y así “aprende” a asignar el output adecuado para los nuevos inputs, es decir, predice el valor de salida.

Dentro de los algoritmos de aprendizaje automático supervisado, este estudio se centra en aquellos modelos que generan una regresión a partir de los input data para predecir los outputs data. En la Figura 2-1 se puede ver un resumen de la clasificación de los algoritmos de machine learning.

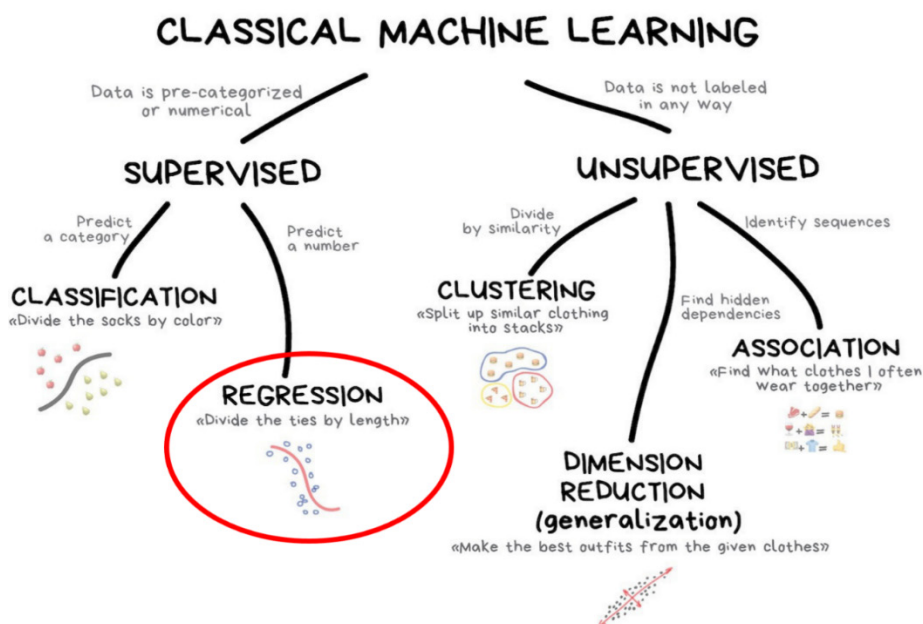


Figura 2-1: Clasificación de los algoritmos de machine learning.

En todos los casos de aprendizaje supervisado enfocado a la regresión, es preciso disponer de una serie de datos para alimentar y validar el modelo. El primer paso para cualquiera de estos tipos de algoritmo consiste en separar de manera aleatoria los datos de los que disponemos en training data y testing data. Los training data son los datos que introducimos en el algoritmo, tanto input data como output data, para alimentarlo, de tal manera que el algoritmo estime las variables que lo definen. Los testing data son los datos que introducimos en el algoritmo, únicamente los testing input data, para posteriormente comparar los valores estimados por el algoritmo a partir de los testing input data con los testing output data, esta comparativa nos dará una idea de la calidad de nuestro modelo.

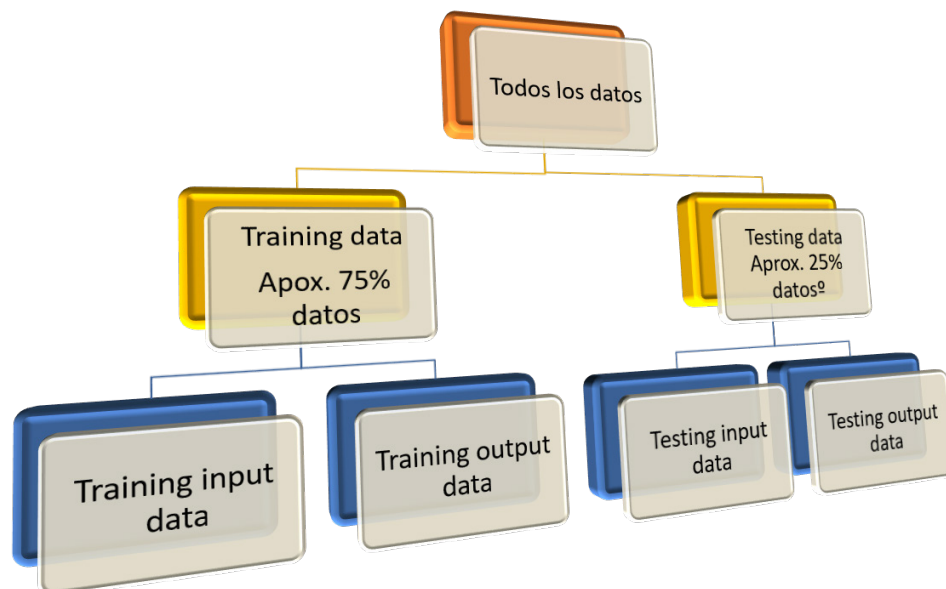


Figura 2-2: Clasificación de los datos en machine learning.

En el presente trabajo se utilizan seis algoritmos de machine learning ampliamente contrastados para generar modelos predictivos. Estos seis modelos son: Multi linear regression [44,45], K-Nearest Neighbor for Regression (KNN) [46,47], Regression tree (RT) [48,49], random forest (RF) [50,51], multilayer perceptron (MLP) [52,53] y Support Vector Regression [54,55]. A continuación, se presenta una pequeña descripción de cada uno de estos modelos.

2.2.1 Multi linear regression (MLR)

El multi linear regression (MLR), también conocido simplemente como regresión múltiple, es una técnica estadística que utiliza varias variables explicativas para predecir el resultado de una variable de respuesta. El objetivo del MLR es modelar la relación lineal entre los input data y los output data.

Este caso se trata del modelo más simple de todos, buscando una regresión a una función del estilo (2.1), donde i es el número de training data.

$$y_i = \beta_0 + \beta_1 * X_{i1} + \beta_2 * X_{i2} + \dots + \beta_n * X_{in} \quad (2.1)$$

En la Figura 2-3 se puede ver un ejemplo explicativo de cómo funciona el algoritmo MLR.




Figura 2-3: MLR explicación.

2.2.2 K-Nearest Neighbor for Regression (KNN)

K nearest neighbors (KNN) es un algoritmo simple que almacena todos los training data y predice el output data numérico basado en una medida de similitud (por ejemplo, funciones de distancia). El KNN se ha utilizado en la estimación estadística y el reconocimiento de patrones ya a principios de los años 70 como una técnica no paramétrica.

El algoritmo KNN asume que cosas similares se encuentran muy cerca entre sí. Para realizar un análisis KNN es preciso definir el número de vecinos que se tienen en cuenta para realizar en análisis (k). Una vez definido el número de vecinos que se van a tener en cuenta, el algoritmo define los k datos más parecidos al que buscamos predecir. A partir de estos k output data, el algoritmo predice el nuevo output data de manera ponderada, por lo que es obligatorio que los inputs data estén siempre normalizados.

En la Figura 2-4 aparece un esquema explicativo de cómo funciona el algoritmo K nearest neighbors.




Figura 2-4: KNN explicación.

2.2.3 Regression tree (RT)

El árbol de decisión construye modelos de regresión o clasificación en forma de estructura de árbol. Descompone un conjunto de datos en subconjuntos cada vez más pequeños mientras que al mismo tiempo se desarrolla gradualmente un árbol de decisión asociado. Lo que implica que, en un primer nivel, separa los datos en dos grandes grupos, que son a priori, los que el algoritmo identifica como más diferentes. Posteriormente, cada una de estas dos ramas se vuelven a dividir en dos en función de lo que el algoritmo identifique como más diferenciante y, así sucesivamente, hasta que llegue al número de niveles que define quien maneja el algoritmo.

En la Figura 2-5 se puede ver un ejemplo del funcionamiento del algoritmo regression tree. En dicho ejemplo, el algoritmo ha identificado que el parámetro más relevante es si la temperatura es superior o inferior a -27.5°C . Posteriormente, en función de si es mayor o menor, ha vuelto a identificar nuevas variables más influyentes. Este análisis se ha realizado un número de veces definido por el usuario del algoritmo. En cada subdivisión se realiza una estimación del output data estimado, tanto más preciso cuanto mayor sea el número de niveles en el algoritmo.

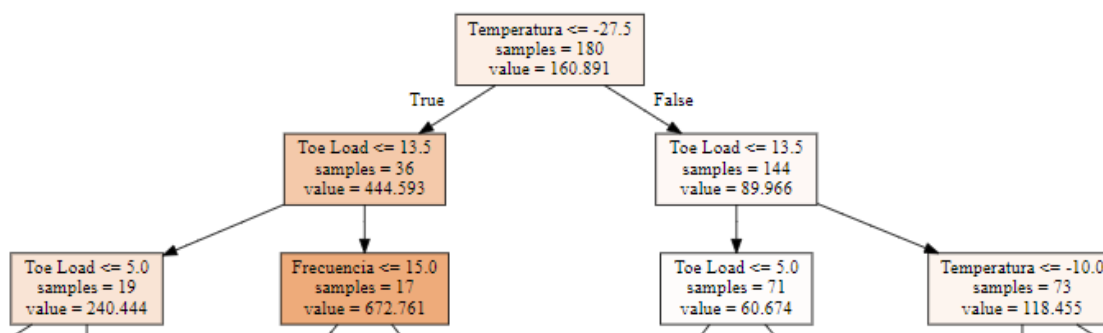


Figura 2-5: RT explicación.

2.2.4 Random forest (RF)

Random Forest (RF) es uno de los algoritmos de aprendizaje automático más utilizados debido a su simplicidad y al hecho de que se puede usar tanto para tareas de clasificación como de regresión. RF es una combinación de RT tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos. En un último paso, cada uno de estos RT “votan” para definir el resultado final del output data.

Una de los grandes valores añadidos que presenta el algoritmo RF es que, a diferencia de la mayor parte de los algoritmos de aprendizaje automático que buscan únicamente obtener predicciones, *Random Forest* permite clasificar las variables en función de su importancia.

En la Figura 2-6 se puede ver un ejemplo explicativo de cómo funciona el algoritmo Random Forest.

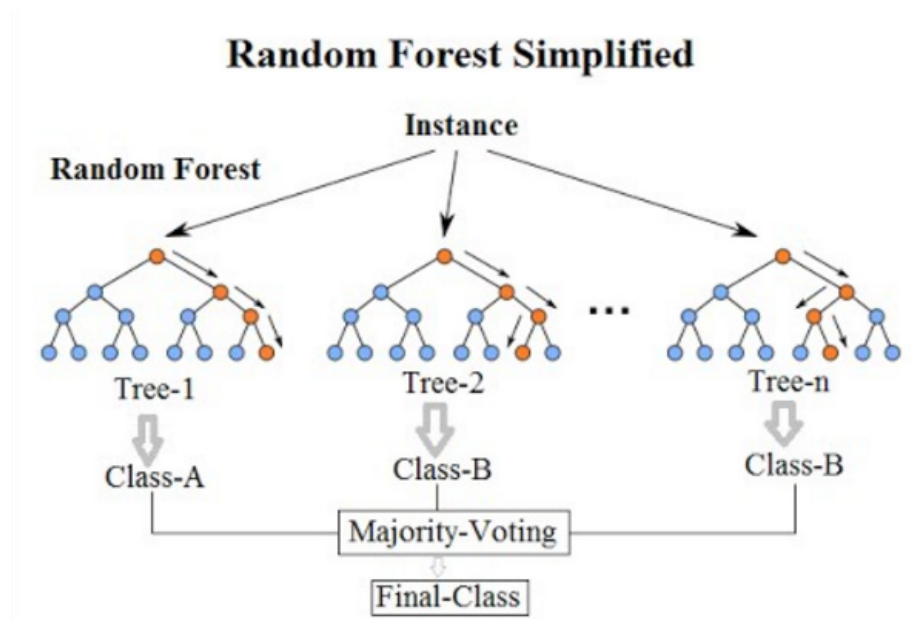


Figura 2-6: RF explicación.

2.2.5 Multilayer perceptron (MLP)

El multilayer perceptron (MLP) es una red neuronal artificial formada por múltiples capas, de tal manera que tiene capacidad para resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón (también llamado perceptrón simple). El perceptrón multicapa puede estar totalmente o localmente conectado. En el primer caso cada salida de una neurona de la capa "i" es entrada de todas las neuronas de la capa "i+1", mientras que en el segundo cada neurona de la capa "i" es entrada de una serie de neuronas (región) de la capa "i+1".




Figura 2-7: MLP explicación.

2.2.6 Support Vector Regression (SVR)

Support Vector Regression (SVR) es una aplicación del algoritmo support vector machine (SVM) aplicado expresamente a la regresión de datos, para poder predecir output data a partir de input data.

Estos modelos funcionan a base de subdividir los datos pertenecientes a training data en grupos lo más ampliamente posible mediante la generación de hiperplanos, esta parte sería la enfocada a la clasificación. De igual manera, es posible predecir un output data una vez se aporten testing data. El procedimiento que siguen estos modelos para estimar el output data, es estimarlo en función de los espacios a los que pertenezca.




Figura 2-8: SVR explicación.

CAPÍTULO 3

Materiales y metodología experimental

En el presente capítulo, se detallan los materiales y los procedimientos de ensayo empleados durante el estudio experimental. El mismo se ha estructurado en tres partes: definición de los materiales utilizados, caracterización mecánica de las placas de asiento utilizadas y regresión mediante modelos de machine learning.

3.1 Materiales

Para el análisis de la influencia de las condiciones de ensayo en la rigidez de la placa de asiento se seleccionaron 3 tipos de placa de asiento, correspondientes con 3 de los materiales más utilizados en la fabricación de este tipo de componente. Los tres materiales utilizados fueron EPDM, TPE y EVA, en la Figura 3-1 se puede ver un ejemplo de cada una de estas placas de asiento.

EPDM: Placa de asiento de EPDM (Etileno Propileno Dieno) de 7 mm de espesor. Se trata de una placa maciza con una dureza de 21 HS-D. Este tipo de placa fue la solución utilizada en la línea de alta velocidad en Arabia Saudí.

TPE: Placa de asiento de TPE (elastómero termoplástico) (Hytrel™) de rigidez media de 7 mm de espesor. Es una placa de asiento aligerada con oblongos situados al tresbolillo y con una dureza de 47 HS-D. Esta solución es la que se utilizó en las líneas de alta velocidad españolas.

EVA: Placa de asiento EVA (etileno-vinil-acetato) de 6 mm de espesor. Es una placa maciza con una dureza de 46 HSD. Esta solución se adoptó en la línea de alta velocidad entre Madrid y Sevilla (España).




Figura 3-1: Placas de asiento analizadas.

3.2 Metodología experimental

En este apartado se detalla el procedimiento seguido para la caracterización y análisis del comportamiento de los tres tipos de placa de asiento definidas en el apartado anterior.

Este apartado se divide a su vez en dos: ensayos de laboratorio y modelos de machine learning. En cada uno de estos apartados se detallan los procedimientos que se han seguido a lo largo de este trabajo fin de master.

3.2.1 Ensayos de laboratorio

Para la caracterización de las placas de asiento se emplearon ensayos de rigidez, tanto estáticos como la dinámicos, tomando como referencia las normas UNE-EN 13146-9 [41] y UNE-EN 13481-2 [40]. Los ensayos se realizaron empleando diferentes temperaturas de ensayo, comenzando por ensayos a temperatura ambiente, según norma 23 ± 5 °C, tras lo cual, se realizaron ensayos a las temperaturas máxima (52°C) y mínima (-35°C) que define la Instrucción sobre las acciones a considerar en el proyecto de puentes de carretera (IAP-11) [56]. De manera adicional, y por considerar un salto excesivo entre la temperatura mínima y ambiente, se analizó la evolución de la rigidez en putos intermedios, -20 y 0 °C. Debido a que los periodos de atemperación a las temperaturas de ensayo son elevados, con el objeto de reducir los tiempos de ensayo se utilizó la misma placa de asiento para los ensayos a la misma temperatura. Se considera que, en ningún caso, los ensayos previos puedan afectar a los posteriores de forma significativa ya que el número de ciclos que se realizan es lo suficientemente pequeño y se mantiene un cierto tiempo de espera entre ensayos.

Para la realización de los ensayos de rigidez se empleó una máquina universal de ensayos servohidráulica dotada de una célula de carga con una capacidad de ± 100 kN y la medida del acortamiento de la placa se realizó por medio de 4 LVDTs (Linear Variable Differential Transformer) colocados sobre una base metálica que simula la geometría de la traviesa. La carga de ensayo se aplicó sobre la placa de asiento por medio de un cupón de carril UIC60 de 200 mm de longitud conectado a la máquina de ensayo por medio de una rótula para garantizar que la carga aplicada es vertical y perpendicular a la placa de ensayo en todo momento. Durante los ensayos de rigidez se registran valores de la carga vertical y del acortamiento de la placa como media de los cuatro captadores de desplazamiento LVDTs.

En la Figura 3-2 puede verse el dispositivo de ensayo para las temperaturas extremas de -35 y 50°C.



(a) Stiffness test -35°C.



(b) Stiffness test +52°C.

Figura 3-2: Ejemplos del dispositivo de ensayo.

Una vez colocado todo el dispositivo dentro de la cámara se mantiene durante una hora la temperatura objetivo, para garantizar que todo el volumen la placa se encuentra a la temperatura de ensayo.

3.2.1.1 Rigidez vertical estática

Para determinar la rigidez estática, una vez garantizado que la placa se encuentra a la temperatura deseada, se realizan tres rampas de carga y descarga entre 1 y 90 kN con una velocidad de 2 kN/s. En la Figura 3-3 (a) se puede ver el esquema de cargas que se aplica para realizar los ensayos de rigidez estática, tal y como definen las normas UNE-EN 13481-2 [40] y UNE-EN 13146-9 [41]. La rigidez estática entre los valores de carga establecidos se obtiene como la variación de carga entre la variación de desplazamiento durante la última de las rampa de carga, véanse (3.1) y Figura 3-3 (b).

$$k_{est} = \frac{F_{final} - F_{initial}}{D_{final} - D_{initial}} \quad (3.1)$$

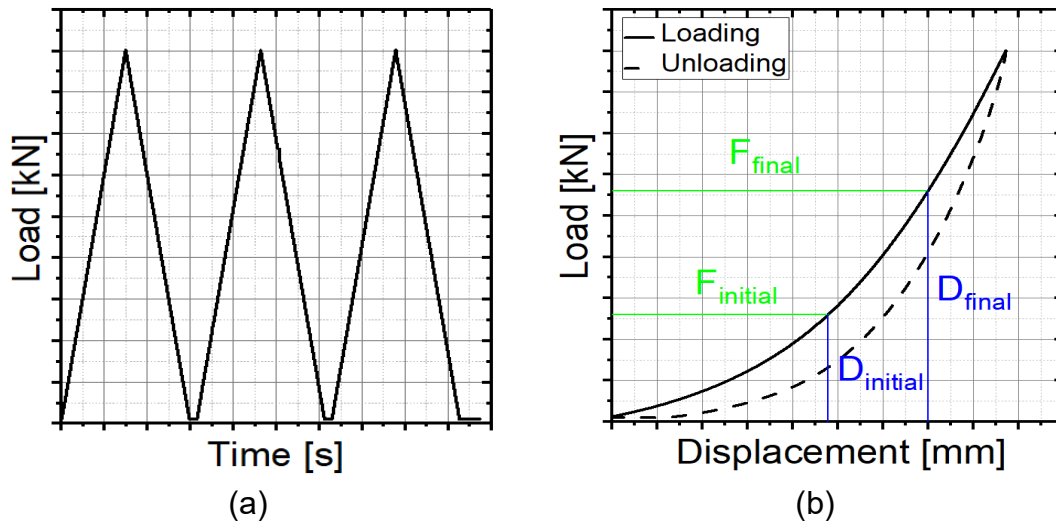


Figura 3-3: (A) procedimiento de ensayo. (b) método de determinación de rigidez estática.

Teniendo en cuenta que el parámetro que se utiliza habitualmente al describir mecánicamente una placa de asiento es la rigidez, se define el parámetro rigidez relativa, k_r , que define el valor de la rigidez para cualquier escenario diferente a las condiciones estándar recogidas en la normativa aplicable. Esta variable se define de acuerdo a la (3.2), donde F_{TL} y D_{TL} se corresponden con los valores de fuerza y desplazamiento en el sistema de sujeción cuando está montado con una fuerza equivalente al Toe Load.

$$(k_e)_r = \frac{F_{max} - F_{TL}}{D_{max} - D_{TL}} \quad (3.2)$$

3.2.1.2 Rigidez vertical dinámica

Los ensayos de rigidez dinámica consistieron en realiza 1000 ciclos de cargas senoidales sobre la placa. En la Figura 3-4 (a) se puede ver la relación entre los parámetros analizados y las cargas aplicadas. La rigidez de la placa se obtiene como la relación entre la media de rango de cargas y la media del rango de desplazamiento de los 100 últimos ciclos de cada ensayo, véanse (3.3) y Figura 3-4 (b).

$$k_{dyn} = \frac{\overline{F_{max}} - \overline{F_{min}}}{\overline{D_{max}} - \overline{D_{min}}} \quad (3.3)$$

Con los ensayos dinámicos se busca analizar la influencia de una serie de parámetros de vía además de la temperatura, ya comentada anteriormente. Concretamente se trata de la amplitud, toe load y de la frecuencia. La carga por eje será función de la carga por eje del tren que circula sobre la vía, el toe load dependerá del estado de la sujeción y, por último, la frecuencia dependerá de la velocidad de paso de la rueda por la sujeción, ver Figura 3-4.

Respecto a los valores de amplitud, se realizaron ensayos usando las 3 amplitudes que define la norma UNE-EN 13481-2 [40] en función de la categoría de la vía; 15.5, 21 y 31.5 kN. Respecto a los valores del Toe load se analizaron 4 posibles situaciones. En primer lugar, un montaje correcto del sistema o situación de referencia de 18 kN, una situación extrema, consecuencia de la rotura de la sujeción de 1kN y dos condiciones adicionales derivadas de un posible exceso o falta de apriete de la sujeción, 9 y 25 kN, respectivamente. Para el análisis de la frecuencia, se analizaron 4 frecuencias de paso 2.5, 5, 10 y 20 Hz. De la combinación del análisis de estos 3 parámetros junto con la temperatura, se obtienen 48 ensayos de rigidez por temperatura y material, o lo que es lo mismo, un total de 720 ensayos de rigidez dinámica. En la Figura 3-5 se puede ver un resumen de los parámetros analizados en este estudio.

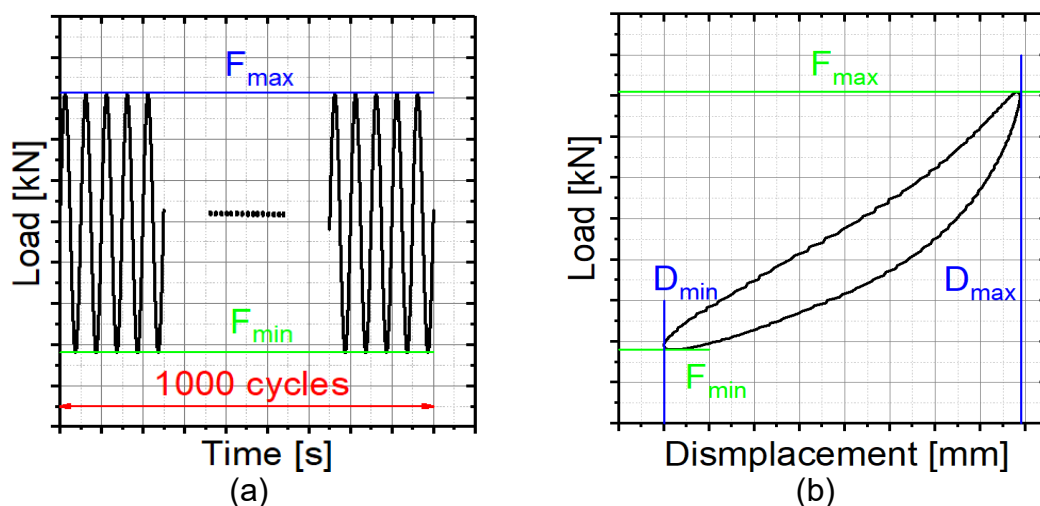


Figura 3-4: (A) procedimiento de ensayo. (b) método de determinación de rigidez dinámica.




Figura 3-5: Tren de cargas aplicadas.

Tabla 3-1: Parámetros analizados.

Temperatura [°C]	Amplitud [kN]	Frecuencia [Hz]	Toe load [kN]
-35	15.5	2.5	1
-20	21.0	5	9
0	31.5	10	18
20		20	25
52			

Para analizar la influencia de cada uno de los parámetros sobre la rigidez vertical de la placa de asiento, se define el coeficiente de influencia, CI, para comprobar cómo afecta y en qué grado cada una de las variables analizadas sobre la rigidez de la placa, (3.4).

$$CI = \frac{R_i}{R_{AV}} \quad (3.4)$$

Donde R_{AV} es la rigidez definida en condiciones standard de alta velocidad, es decir Toe Load: 18 kN, amplitud de carga: 31.5 kN, frecuencia: 5 Hz y Temperatura ambiente, mientras que R_i es la rigidez en la que únicamente se modifica la variable a analizar, manteniendo el resto como condiciones estándar de alta velocidad. De forma que un resultado próximo a 1 significa que esa variable analizada supone un cambio mínimo respecto a las condiciones estándar y mientras más se aleja de la unidad supondrá que se produce una rigidización si $CI > 1$ y una flexibilización si $CI < 1$.

3.2.2 Modelos de machine learning

Para el análisis de los resultados de laboratorio descritos en el apartado anterior se aplicaron seis algoritmos de machine learning orientados a la regresión para reproducir lo mejor posible el comportamiento de cada una de las tres placas de asiento a lo largo de todo el rango de los parámetros estudiados.

Para implementar los algoritmos de machine learning se utilizó el lenguaje de programación Python, usando principalmente las librerías Numpy, Pandas y Sklearn.

En el presente trabajo se utilizan seis algoritmos de machine learning ampliamente contrastados para generar modelos predictivos. Estos seis modelos son: Multi linear regression, K-Nearest Neighbor for Regression (KNN), Regression tree (RT), random forest (RF), multilayer perceptron (MLP) y Support Vector Regression. A continuación, se presenta una pequeña descripción de cada uno de estos algoritmos.

En este apartado se explican de manera detallado los procedimientos seguidos.

3.2.2.1 Selección del modelo óptimo para cada material

Se parte de la premisa de que en machine learning no existe ningún algoritmo mejor que otro, si no uno que se ajusta mejor que otro. Se alimentó cada uno de los algoritmos de machine learning previamente mencionados con los training data y, posteriormente, se analizó la calidad del modelo a través de los testing data. Tras este análisis, se seleccionó como modelo óptimo aquel que presentaba mejor relación entre los datos estimados y los testing output data. De manera adicional, se dibujaron las bandas de confianza que de igual manera aportan una cierta información sobre la idoneidad del modelo.

3.2.2.2 Análisis de la relevancia de cada una de las variables analizadas

En este apartado se busca identificar que input data tienen una mayor repercusión en la rigidez vertical dinámica de cada uno de los 3 materiales analizados. Para ello se utilizaron 2 procedimientos distintos, en primer lugar, mediante el feature importance y, en segundo lugar, permutation importance.

Feature importance es un procedimiento que permite estimar la relevancia de cada uno de los input data a través de un modelo de RF. Es un procedimiento ampliamente contrastado y una de las grandes ventajas del método RF.

Permutation importance es un algoritmo que, de igual manera, permite clasificar los input data en función de cuanto afectan a los output data. Este procedimiento comienza por estimar los testing data output a partir de los testing data inputs. Posteriormente, se separa de una en una las variables de los testing inputs data y se reordenan de manera aleatoria todos los valores de esa variable. Se vuelven a estimar los valores tomando como input data los testing input data pero con los datos de una de las variables desordenados. Una vez obtenidos estos nuevos valores, se compararán con los testing output data, si existe una gran variación, implica que esta primera variable será muy relevante, si por el contrario la diferencia es pequeña, se tratará de un parámetro poco importante. Este procedimiento se repetirá con cada una de las variables existentes.

3.2.2.3 Análisis cuantitativo de la influencia de cada uno de los parámetros

Para analizar cómo es la influencia de cada una de las variables, se utilizó la técnica denominada partial dependence plots, que muestra el efecto marginal de una variable en el valor predicho por el modelo. Los partial dependence plots muestran si la relación entre el output data y una variable de los input data es lineal, monótona o más compleja [57].

CAPÍTULO 4

Resultados y análisis de los resultados

En este apartado, se presentan los resultados de los ensayos de laboratorio realizados durante este trabajo fin de master, junto con el análisis de los mismos. El orden seguido en este apartado para la presentación de los resultados es similar al que se ha desarrollado en el capítulo anterior, “CAPÍTULO 3 Materiales y metodología experimental”, estructurándolo en dos grandes grupos: ensayos de laboratorio y machine learning.

4.1 Ensayos de laboratorio

Para el análisis de la influencia de los parámetros ya mencionados, se optó por definir una combinación de parámetros patrón que serán los establecidos por la normativa vigente para la alta velocidad y que serán tomados como referencia, es decir: temperatura 20 °C, amplitud de carga 31.5 kN, toe load 18 kN y frecuencia 5 Hz.

4.1.1 Rigidez vertical estática

En primer lugar, se compararon las curvas de fuerza desplazamiento de cada uno de los 3 materiales a temperatura ambiente, véase Figura 4-1. Se puede apreciar que los 3 materiales tienen un comportamiento claramente diferenciado. El EPDM sufre una deformación mucho mayor que los otros dos materiales, sobre todo en el tramo inicial, hasta 50 kN, valor a partir del cual sufre una rigidización, el TPE una deformación intermedia y más constante en todo el rango de cargas y, por último, la placa de EVA es la que menos se deforma, pero que presenta la mayor parte de su deformación en el primer tramo de carga, hasta 20 kN. Estos resultados concuerdan con los resultados obtenidos por otros autores [58].




Figura 4-1: Comparativa de las curvas fuerza-desplazamiento de las tres placas de asiento seleccionadas en las condiciones de alta velocidad.

En la Figura 4-2 se puede ver una comparativa de las curvas carga-desplazamiento para las 5 temperaturas estudiadas de cada uno de los materiales.




Figura 4-2: Influencia de la temperatura en la rigidez vertical estática para las condiciones estandarizadas de toe load, frecuencia y amplitud.

Sobre la Figura 4-2 se puede realizar un primer análisis de cómo afecta la temperatura a la rigidez vertical de cada una de las placas de asiento al ser sometidas a una carga. En el caso del EPDM, se puede apreciar que hasta la temperatura de -20°C , la variación es mínima, mientras que al bajar a -35°C , se aprecia que la placa sufre un claro incremento de la rigidez. En el caso del TPE, se puede ver que la disminución de la temperatura de ensayo genera una reducción de la deformación que sufre la placa de manera gradual y por tanto un incremento proporcional de la rigidez. Por último, en el caso de la placa de EVA, se puede apreciar una clara flexibilización para temperaturas comprendidas entre 0 y 20°C , apareciendo dos grupos claramente diferenciados, por encima de la temperatura ambiente y por debajo de los 0°C .

Hasta el momento, se han analizado las curvas clásicas de rigidez, es decir la variación de la fuerza aplicada frente al acortamiento sufrido por la placa. En las Figura 4-3 y Figura 4-4 se representan las rigideces relativas tal y como se definieron en el apartado anterior.

En la Figura 4-3 se puede ver la influencia tanto del rango de cargas como de la temperatura sobre la rigidez vertical estática relativa de cada uno de los 3 materiales cuando el sistema está sometido a un Toe Load de 18 kN.




Figura 4-3: Influencia de la temperatura y la amplitud de carga en la rigidez vertical estática para condiciones de toe load estandarizadas para alta velocidad.

De la Figura 4-3 se puede apreciar que, al incrementar el rango de cargas entre las que se calcula la rigidez, en todos los casos, la rigidez de la placa de asiento aumenta. Además, el crecimiento en todos los casos es con pendiente creciente, salvo el TPE por encima de la temperatura ambiente, debido a la geometría maciza del EPDM y EVA y a que el TPE para temperaturas elevadas agota la geometría rápidamente.

Respecto a la influencia de la temperatura sobre rigidez vertical estática de las placas de asiento, se puede ver que a cada uno de los materiales le afecta de una manera distinta. En el caso del EPDM, tal y como se había detectado del análisis de las curvas carga-desplazamiento, la temperatura únicamente tiene una influencia marcada en el caso de que la temperatura sea inferior a -20°C , de lo contrario la rigidez prácticamente no se ve influenciada. En el caso del TPE, al reducir la temperatura la placa de asiento se va rigidizando de una manera progresiva. En el caso del EVA, de manera opuesta al EPDM, para las temperaturas bajas, no se aprecian variaciones en la rigidez de las placas de asiento, mientras que cuando aumenta la temperatura se puede ver que las placas pierden rigidez. Es decir, de forma resumida, el EPDM presenta un comportamiento uniforme a temperaturas altas, el EVA es uniforme a temperaturas bajas y el TPE se distribuye de forma uniforme en todo el rango de estudio.

De manera análoga al análisis hecho sobre la influencia de la temperatura, se analizó la influencia del toe load sobre la rigidez vertical estática relativa de cada una de estas placas para la situación de temperatura ambiente, véase Figura 4-4.




Figura 4-4: Influencia de la temperatura y la amplitud de carga en la rigidez vertical estática para condiciones de toe load estandarizadas para alta velocidad.

En la Figura 4-4 se puede ver que, aunque de manera general, un aumento en el toe load produce un incremento de la rigidez vertical estática de la placa, afecta de manera claramente distinta a cada uno de los materiales. En el caso del EPDM, la influencia del toe load es pequeña para variaciones de carga pequeñas, pero aumenta al incrementar las cargas. En el caso del TPE, por el contrario, tiene una influencia mayor cuando la variación de carga es pequeña y, la influencia se reduce al incrementar la carga. El caso de las placas de EVA el efecto del toe load es importante y uniforme a lo largo de todo el rango de cargas analizado.

4.1.2 Rigidez vertical dinámica

El análisis de la influencia de la frecuencia, amplitud de carga, toe load o temperatura sobre la rigidez dinámica de la placa de asiento comenzó por comparar la curva de carga-deformación de los tres materiales en las condiciones que define la norma UNE-EN 13146-9 [41] y UNE-EN 13481-2 [40] para la alta velocidad. En la Figura 4-5 se puede ver la comparativa entre los 3 materiales. Se puede ver que, en primer lugar, que el EPDM es el material más flexible y que mayor energía disipa por ciclo, seguido por el TPE y por último el EVA.




Figura 4-5: Comparativa de las curvas fuerza-desplazamiento dinámicas de las tres placas de asiento seleccionadas en las condiciones de alta velocidad.

Para analizar la influencia de cada una de las variables, se tomó como referencia las condiciones que dicta la norma para los ensayos de alta velocidad, fijando en cada comparativa 3 de las variables en las condiciones de alta velocidad y dibujando el resto de las situaciones analizadas.

Por último, en la Figura 4-6, vemos la influencia de la temperatura sobre la rigidez dinámica manteniendo constantes el resto de variables. Del análisis de la Figura 4-6 se puede apreciar que la temperatura de ensayo afecta de manera claramente diferente a cada uno de los materiales. En el caso del EPDM, se puede apreciar que hasta la temperatura de 0 °C, las curvas carga desplazamiento son similares, mientras que, a -20°C se puede detectar un cierto grado de rigidización que se acentúa al bajar la temperatura hasta -35°C. Dado que este comportamiento puede resultar sorprendente, se realizó una prueba específica sobre la placa de EPDM para verificar este comportamiento y que se muestra más adelante. En el caso del TPE, se puede apreciar que la temperatura tiene una influencia notable sobre la rigidez de la placa de asiento modificándose la misma de forma progresiva con el incremento de temperatura. Por el contrario, a temperatura ambiente parece que el EVA es un material termoestable, ya que parece que la respuesta de vertical de la placa de asiento se mantiene aproximadamente constante independientemente de la temperatura.




Figura 4-6: Influencia de la temperatura en la rigidez vertical dinámica. La amplitud, la frecuencia y el toe load se han mantenido constantes en los valores estandarizaos para la alta velocidad.

En la Figura 4-7 se puede ver la influencia de la carga por eje sobre la rigidez dinámica de la placa. Se puede apreciar que la amplitud de carga en el ensayo modifica la rigidez principalmente en el caso del EPDM, mientras que en el caso del TPE y del EVA la rigidez se ve mínimamente afectada. En el caso del EPDM, como se detectó analizando la rigidez estática, se puede apreciar un crecimiento progresivo de la pendiente al aumentar la carga, por lo que al ir aumentando la amplitud de carga se incrementa la rigidez de la placa de asiento.




Figura 4-7: Influencia de la amplitud en la rigidez vertical dinámica. La temperatura, la frecuencia y el toe load se han mantenido constantes en los valores estandarizaos para la alta velocidad.

Posteriormente, en la Figura 4-8, se puede observar la influencia del toe load sobre la rigidez dinámica. El toe load afecta de manera sensiblemente diferente a los 3 materiales, tal y como se detectó en el caso estático. En el caso del EPDM, se puede ver un incremento del desplazamiento notable al reducir el toe load, especialmente para toe loads menores de 18 kN. Cabe destacar el notable incremento en la energía disipada para el caso en el que el toe load es 1 kN. El TPE es el material al que menos le afecta este parámetro, aunque cuando el toe load es muy pequeño sí se detecta una variación notable en la rigidez. La placa de EVA es a la que más afecta la reducción del toe load hasta valores de 1 kN, dado que, como ya se indicó previamente, en el primer tramo de carga del EVA el comportamiento es claramente más flexible que cuando se incrementa la carga aplicada.




Figura 4-8: Influencia del toe load en la rigidez vertical dinámica. La amplitud, la frecuencia y la temperatura se han mantenido constantes en los valores estandarizados para la alta velocidad.

En la Figura 4-9, por su parte, se puede ver la influencia de la frecuencia. Se puede observar que el incremento de la frecuencia afecta de manera similar a los 3 materiales, aumentando ligeramente la rigidez de la placa de asiento pero aumentando notablemente la energía disipada por ciclo.




Figura 4-9: Influencia de la frecuencia en la rigidez vertical dinámica. La amplitud, la temperatura y el toe load se han mantenido constantes en los valores estandarizaos para la alta velocidad.

Como se comentó en el párrafo anterior y debido a que se encontró que el EPDM tenía un comportamiento más o menos estable hasta los -20°C pero se detectó una gran variación de rigidez en los ensayos realizados a -35°C , se optó por realizar un ensayo de fatiga específico para analizar este cambio. Sobre una placa de EPDM, dentro de una cámara climática, se programó una fatiga sinusoidal con un valor medio de 40 kN y una amplitud de 35 kN a una frecuencia de 5 Hz. Esta fatiga se mantuvo a temperatura ambiente durante una hora para garantizar que se llegaba a un acondicionamiento estable. Una vez transcurrido este periodo de estabilización, se puso en marcha la cámara climática con la temperatura objetivo de -35°C a una velocidad de $1^{\circ}\text{C}/\text{min}$. Durante este periodo de tiempo, se registró la fuerza y el desplazamiento de los LVDts, como en el resto de los ensayos, y, de manera adicional, se fijó un termopar a la cara lateral de la placa de asiento para registrar la evolución de la temperatura de la misma. De este ensayo se pudo determinar la evolución de la rigidez dinámica vertical de la placa en función de la temperatura de la misma, ver Figura 4-10.




Figura 4-10 Influencia de la temperatura en la rigidez vertical dinámica del EPDM.

En esta figura se puede ver que la rigidez vertical dinámica se mantiene prácticamente constante hasta los 0 °C, sufriendo una ligera rigidización hasta los -20°C. Cuando la temperatura es inferior a -30°C el material sufre una rigidización extrema. Estos valores concuerdan con los resultados obtenidos por Wei et al. [59], que aprecian que la rigidez estática de una placa de EPDM comienza a aumentar al encontrarse por debajo de -10°C y a partir de -20°C dicha rigidización se acelera de manera notable y con los obtenidos en la primera parte del presente estudio.

En las Tabla 4-2 a Tabla 4-1 se pueden ver el calor de CI para todas las variables analizadas.

Tabla 4-1: Influencia de la temperatura en la rigidez vertical dinámica.

Temperature [°C]	-35	-20	0	52
EPDM	5.15	1.60	1.05	0.96
TPE	2.39	1.56	1.24	0.87
EVA	1.01	1.14	1.15	1.12

Tabla 4-2: Influencia de la amplitud en la rigidez vertical dinámica.

Amplitude [kN]	15.5	21.0
EPDM	0.65	0.76
TPE	0.98	0.98
EVA	0.84	0.90

Tabla 4-3: Influencia de la amplitud en la rigidez vertical dinámica.

Toe load [kN]	1	9	25
EPDM	0.54	0.69	1.41
TPE	0.74	0.91	1.06
EVA	0.5	0.81	1.12

Tabla 4-4: Influencia de la frecuencia en la rigidez vertical dinámica.

Frequency [Hz]	2.5	10	20
EPDM	0.86	1.02	1.07
TPE	0.94	1.03	1.13
EVA	0.87	1.05	1.17

Por último, en la Tabla 4-5 se indica el grado de influencia de cada una de las variables en función de la placa analizada. El criterio seguido para asignar estos grados de influencia ha sido en función de CI de forma que la grado bajo implica variaciones de CI se encuentra entre 0.9 y 1.1, un grado medio serían variaciones entre el 0.8-0.9 y 1.1-1.25 del CI y por último para se indica un grado alto para variaciones de CI por debajo de 0.8 o por encima del 1.25 %.

Tabla 4-5: Grado de influencia de cada uno de los parámetros analizados en la rigidez vertical dinámica.

Parámetro	EPDM	TPE	EVA
Amplitud	Alta	Baja	Media
Toe load	Alta	Media-baja	Media-alta
Frecuencia	Media-baja	Media-baja	Media-baja
Temperatura	Alta (si temperatura baja)	Alta	Media-baja

4.2 Modelos de machine learning

En este apartado se utilizaron los 240 resultados obtenidos por cada material para alimentar y validar un modelo de machine learning por cada material.

4.2.1 Selección del modelo óptimo para cada material

En las Figura 4-11 a Figura 4-13 se puede ver una representación de los testing output data frente a los datos estimados a partir de los testing input data, el modelo será tanto mejor cuanto más próximos se encuentren los puntos a la recta 1:1. Por su parte, en las Tabla 4-6 a Tabla 4-8 se pueden ver los parámetros estadísticos de cada uno de estos modelos. Estos parámetros estadísticos serán los que se utilizaron para seleccionar el modelo optimo en cada caso:

R^2 : coeficiente de determinación

RMSE: error cuadrático medio

MAE: Error medio absoluto.

MAPE: Error Porcentual Absoluto Medio

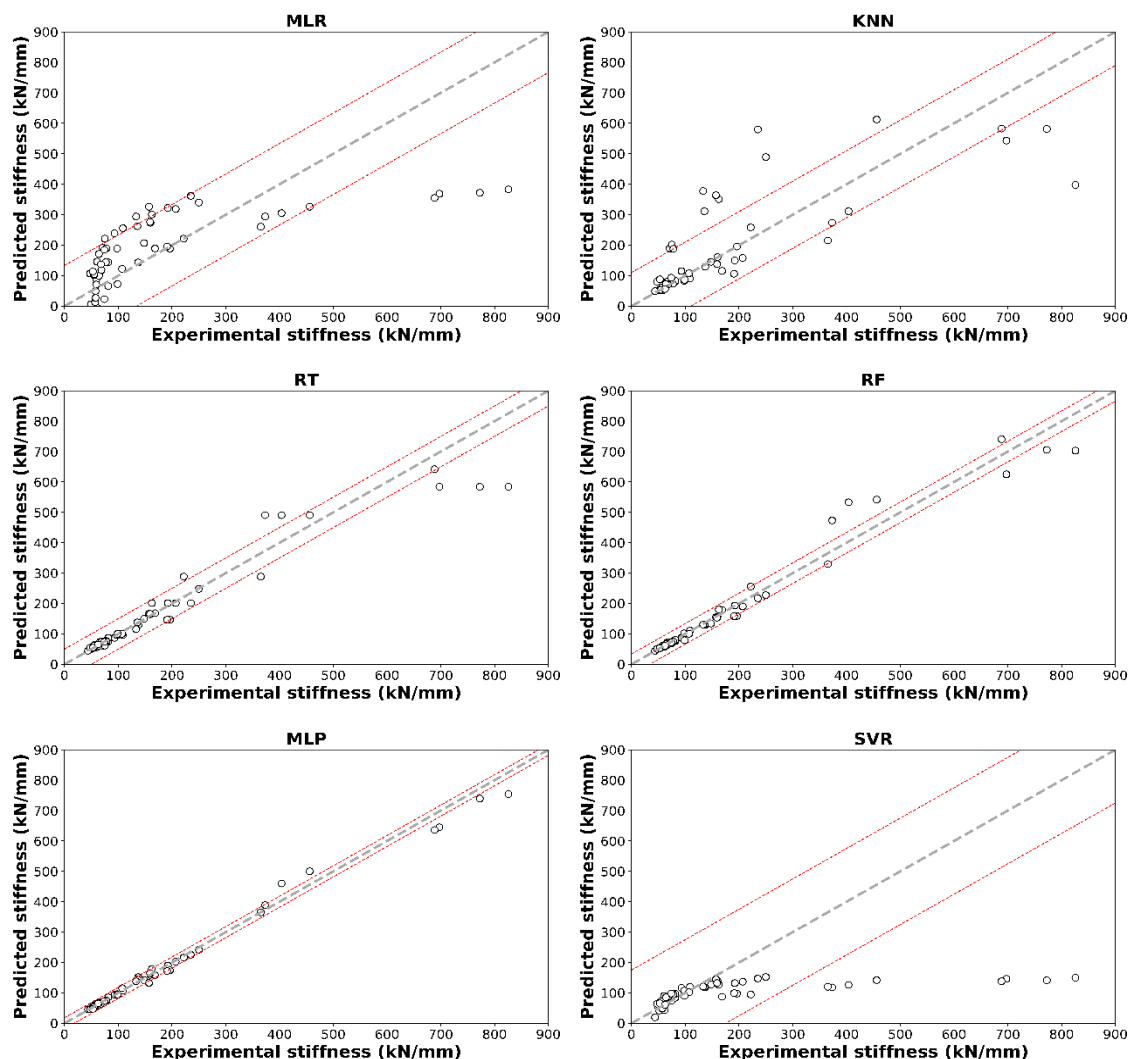


Figura 4-11: Comparativa entre los resultados mediante ensayos de laboratorio y los predichos por el modelo para la placa de asiento de EPDM.

Tabla 4-6: Parámetros estadísticos de los modelos para la placa de asiento de EPDM.

EPDM	R ²	RMSE [kN/mm]	MAE [kN/mm]	MAPE [%]
Multilinear regression	0.452	100.39	133.67	88.78
KNN	0.628	61.58	110.14	34.76
Árbol de decisión	0.923	22.75	50.07	9.24
Random forest	0.965	16.45	33.66	6.18
Multi layer perceptron	0.990	10.23	17.96	6.51
SVM	0.060	81.28	175.13	30.44

En el caso del EPDM, se puede comprobar que el modelo que mejor se ajusta es el multi layer perceptron seguido de cerca por el random forest.

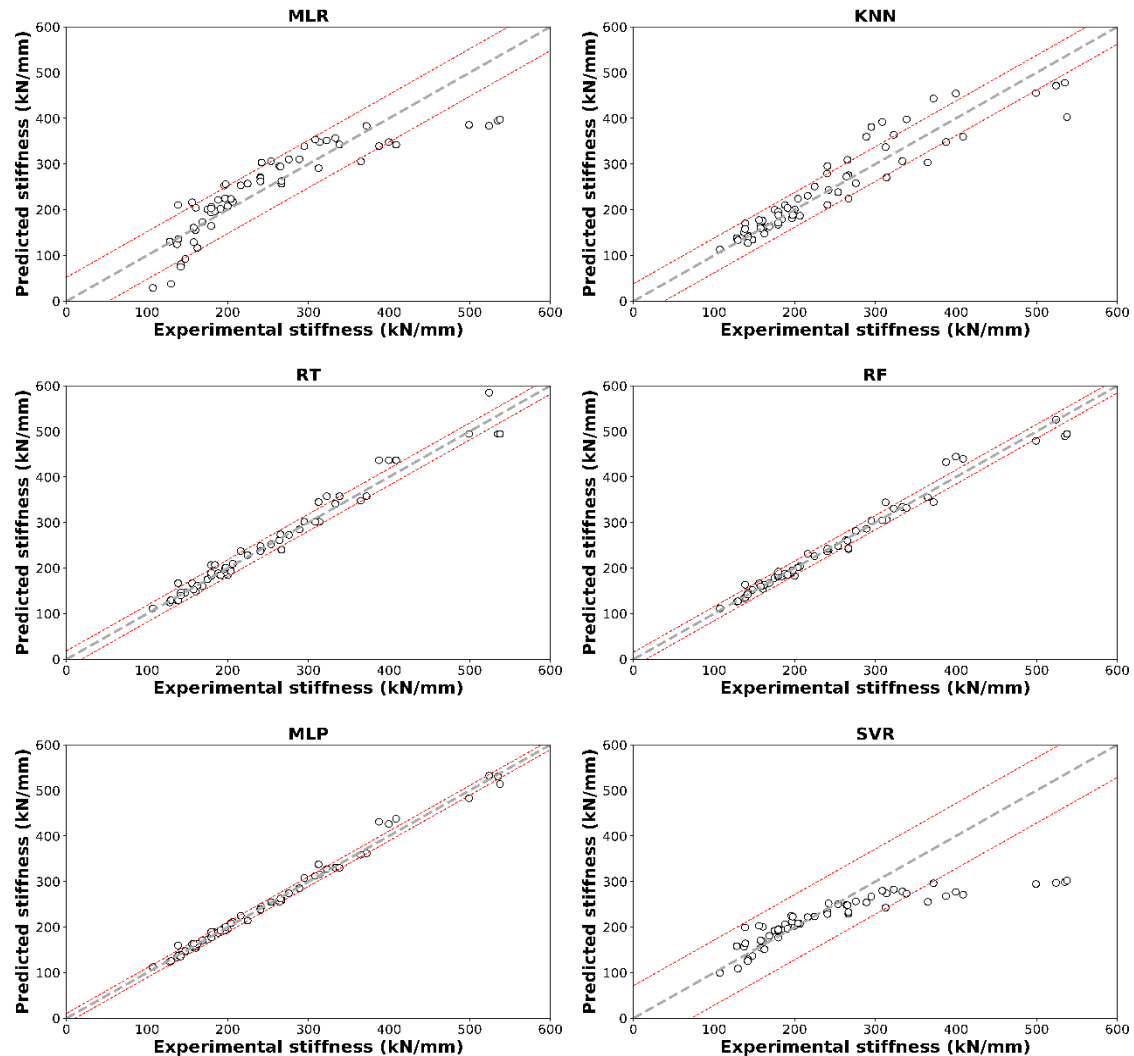


Figura 4-12: Comparativa entre los resultados mediante ensayos de laboratorio y los predichos por el modelo para la placa de asiento de TPE.

Tabla 4-7: Parámetros estadísticos de los modelos para la placa de asiento de TPE.

TPE	R ²	RMSE [kN/mm]	MAE [kN/mm]	MAPE [%]
Multilinear regression	0.759	40.18	52.02	17.83
KNN	0.872	27.73	37.99	10.18
Árbol de decisión	0.969	12.48	18.52	4.72
Random forest	0.977	9.86	16.18	3.45
Multi layer perceptron	0.994	5.8	8.02	2.32
SVM	0.545	42.2	71.49	13.99

En el caso del TPE, se puede comprobar que el modelo que mejor se ajusta es también el multi layer perceptron seguido de cerca por el random forest.

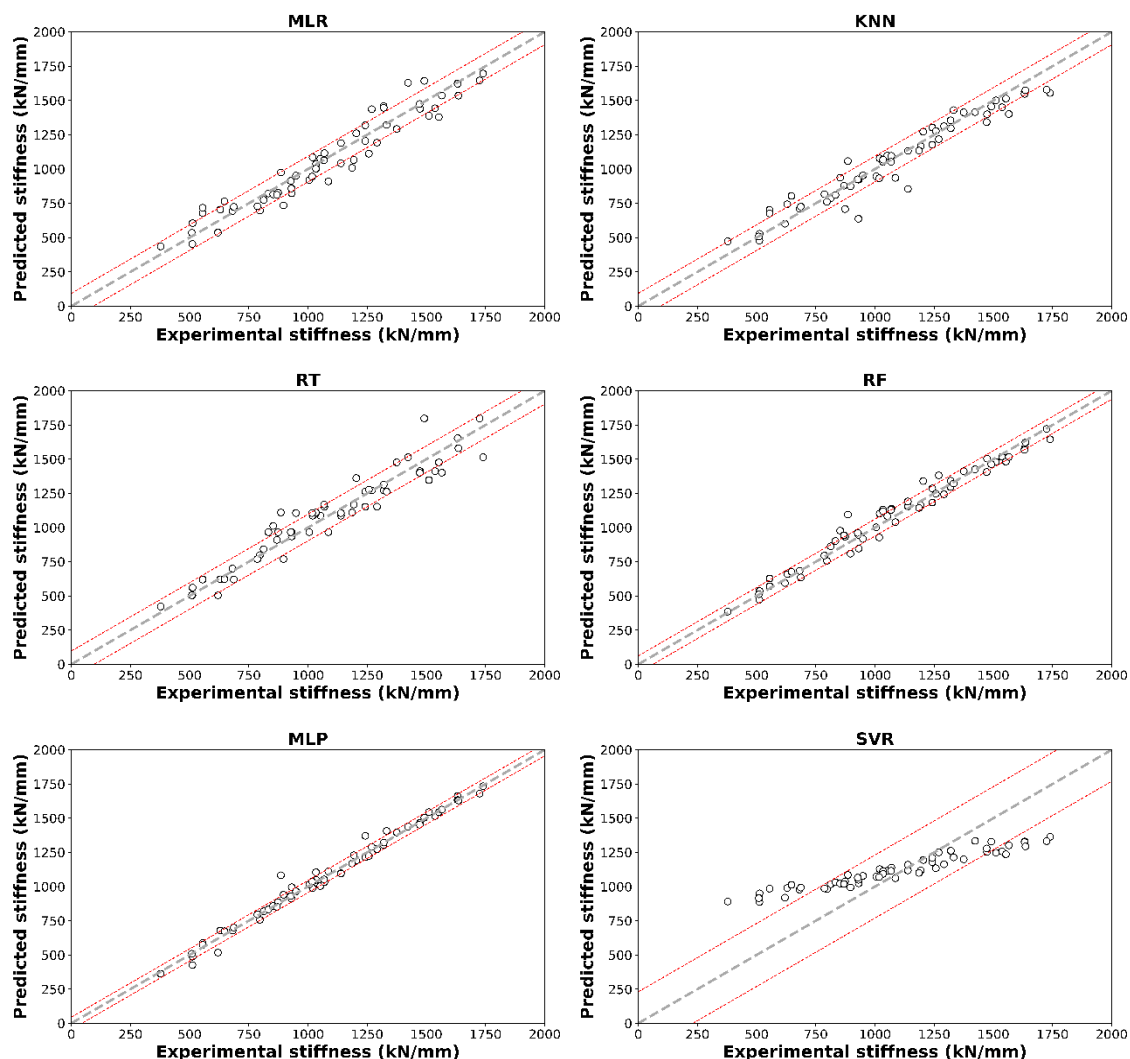


Figura 4-13: Comparativa entre los resultados mediante ensayos de laboratorio y los predichos por el modelo para la placa de asiento de EVA.

Tabla 4-8: Parámetros estadísticos de los modelos para la placa de asiento de EVA.

EVA	R ²	RMSE [kN/mm]	MAE [kN/mm]	MAPE [%]
Multilinear regression	0.93	76.62	93.24	7.88
KNN	0.93	67.93	93.64	7.04
Árbol de decisión	0.92	75.15	97.02	7.17
Random forest	0.97	50.23	62.52	4.91
Multi layer perceptron	0.93	78.3	93.72	7.97
SVM	0.56	188.92	230.44	22.85

En el caso del EVA, se puede comprobar que el modelo que mejor se ajusta en este caso es el random forest, obteniéndose en el resto de los modelos valores similares, pero ligeramente peores salvo en el caso del SVM que son claramente peores.

4.2.2 Análisis de la relevancia de cada una de las variables analizadas

En las Tabla 4-9 a Tabla 4-11 se presentan los valores tanto del feature importance como del permutation importance. Cabe destacar que, en el caso del feature importance la suma de todos los términos es 1, lo que no se cumple en el caso del permutation importance.

En la Figura 4-14 están estos valores representados lo que facilita el análisis tanto de los parámetros más influyentes para cada material como si ambos procedimientos dan lugar a resultados similares.

Tabla 4-9: Análisis de relevancia para la placa de asiento de EPDM.

EPDM	Feature importance	Permutation importance
Temperature	0.64	1.43 ± 0.34
Toe Load	0.30	0.72 ± 0.09
Frequency	0.04	0.10 ± 0.05
Amplitude	0.02	0.02 ± 0.00

Tabla 4-10: Análisis de relevancia para la placa de asiento de TPE.

TPE	Feature importance	Permutation importance
Temperature	0.67	1.4516 ± 0.1761
Toe Load	0.29	0.6153 ± 0.0716
Frequency	0.03	0.0663 ± 0.0199
Amplitude	0.01	0.0186 ± 0.0072

Tabla 4-11: Análisis de relevancia para la placa de asiento de EVA.

EVA	Feature importance	Permutation importance
Toe Load	0.82	1.6997 ± 0.2153
Amplitude	0.08	0.1484 ± 0.0282
Frequency	0.06	0.1096 ± 0.0282
Temperature	0.04	0.0079 ± 0.0047

Se puede apreciar que, en todos los casos los resultados proporcionados por ambos métodos son similares. Se aprecia que en el caso del EPDM los parámetros más influyentes son temperatura y toe load. En el caso del TPE, al igual que en el caso del EPDM, la temperatura y toe load son los parámetros más influyentes. Por su parte, en el caso del EVA, el Toe load es el parámetro más influyente.




Figura 4-14: Análisis cuantitativo de relevancia de los tres tipos de placas de asiento analizadas.

Si se comparan estos resultados con las conclusiones extraídas del análisis convencional de los ensayos de rigidez, se puede comprobar que son concordantes.

Cabe destacar que los parámetros que mayor influencia tienen son los parámetros relativos a las condiciones de la vía, temperatura y estado de la sujeción, por encima de las que dependen del vehículo que circule sobre la vía: carga por eje y frecuencia.

4.2.3 Análisis cuantitativo de la influencia de cada uno de los parámetros

En las Figura 4-15 a Figura 4-17 se representan los partial dependence plots de cada uno de los materiales respectivamente.

La Figura 4-15 permite analizar la influencia de cada una de las variables sobre la placa de EPDM. De la Figura 4-15 (a) se puede apreciar que la influencia del axle load es pequeña cuando esta es pequeña, pero aumenta con la carga. De la Figura 4-15 (b) se puede apreciar que la influencia de la frecuencia es aproximadamente lineal. Si bien en el apartado anterior comentábamos que la temperatura es el parámetro más crítico en la rigidez vertical dinámica de las placas de EPDM, la Figura 4-15 (c) indica que en una primera parte, hasta aproximadamente $-20\text{ }^{\circ}\text{C}$ existe un cambio brusco en el grado de influencia, mientras que a partir de esa temperatura, la influencia de la temperatura es notablemente menor. Sobre la influencia del toe load, la Figura 4-15 (d) muestra que para valores pequeños de toe load, no se parecía grandes modificaciones en la rigidez vertical dinámica de la placa, por su parte, se ve que cuando se aumenta este valor de toe load la placa de asiento se rigidiza notablemente.

En la Figura 4-16 se puede ver la influencia de cada una de las variables analizadas en las placas de asiento de TPE. En la Figura 4-16 (a) se puede ver que la influencia del axle load se reduce notablemente una vez que se alcanza un cierto umbral próximo a los 20 kN de amplitud. En la Figura 4-16 (b) se ve que la influencia de la frecuencia es pequeña y más o menos uniforme. En este caso, a diferencia del caso del EPDM, respecto a la influencia de la temperatura, vease Figura 4-16 (c), si bien la influencia de la temperatura es grande, en este caso, se trata de una variación uniforme. De la Figura 4-16 (d) podemos interpretar que la variación de rigidez que genera la variación de toe load es aproximadamente uniforme.

En la Figura 4-17 se puede ver la influencia de cada una de las variables analizadas en las placas de asiento de EVA. En las Figura 4-17 (a) a (c) se puede ver que la influencia es pequeña, mientras que en Figura 4-17 (d) se ve que la influencia del toe load es muy grande y que se va reduciendo según aumenta el toe load.

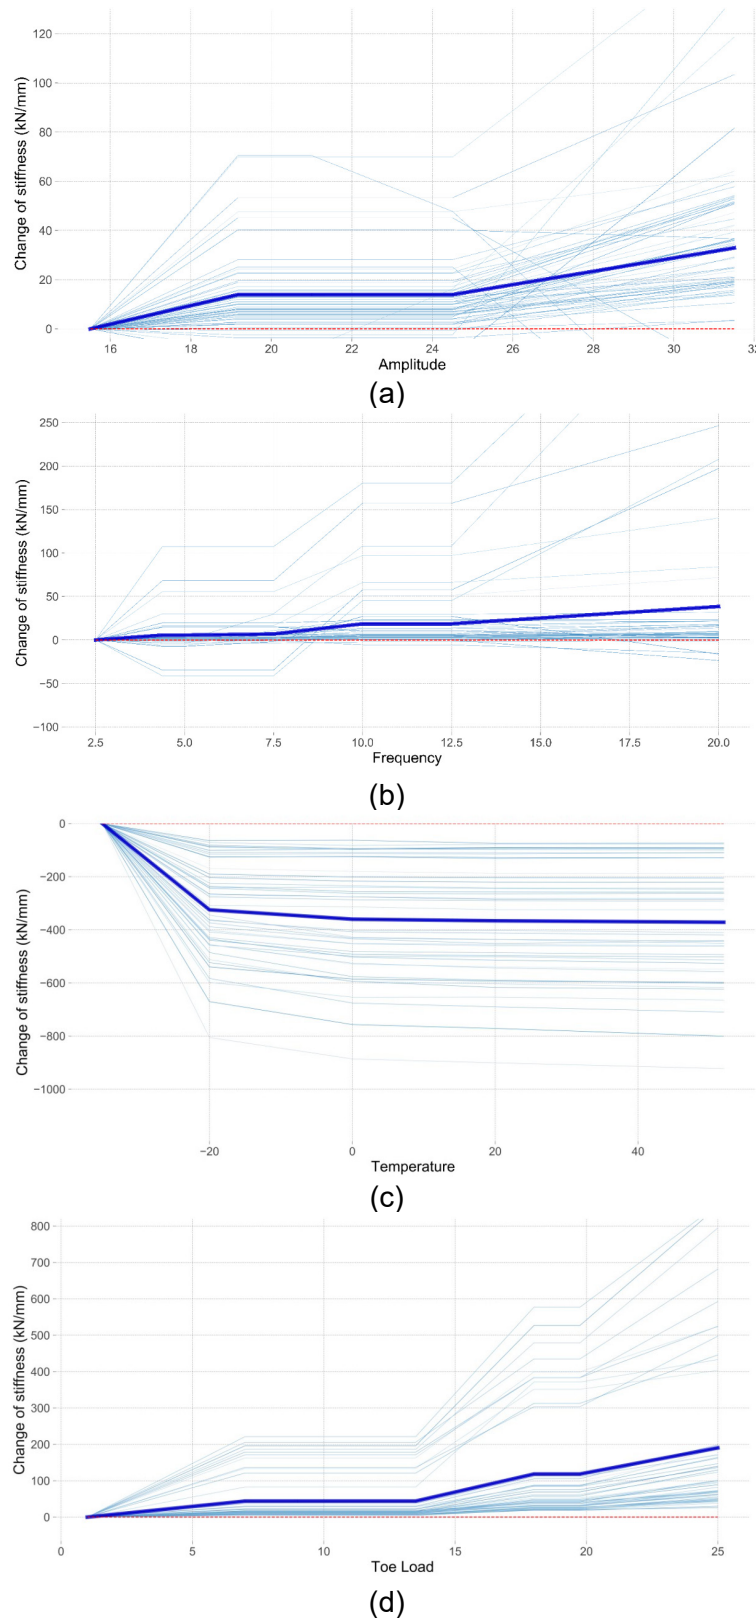





Figura 4-15: Partial dependence plots de la placa de asiento de EPDM.




(a)



(b)



(c)



(d)

Figura 4-16: Partial dependence plots de la placa de asiento de TPE.

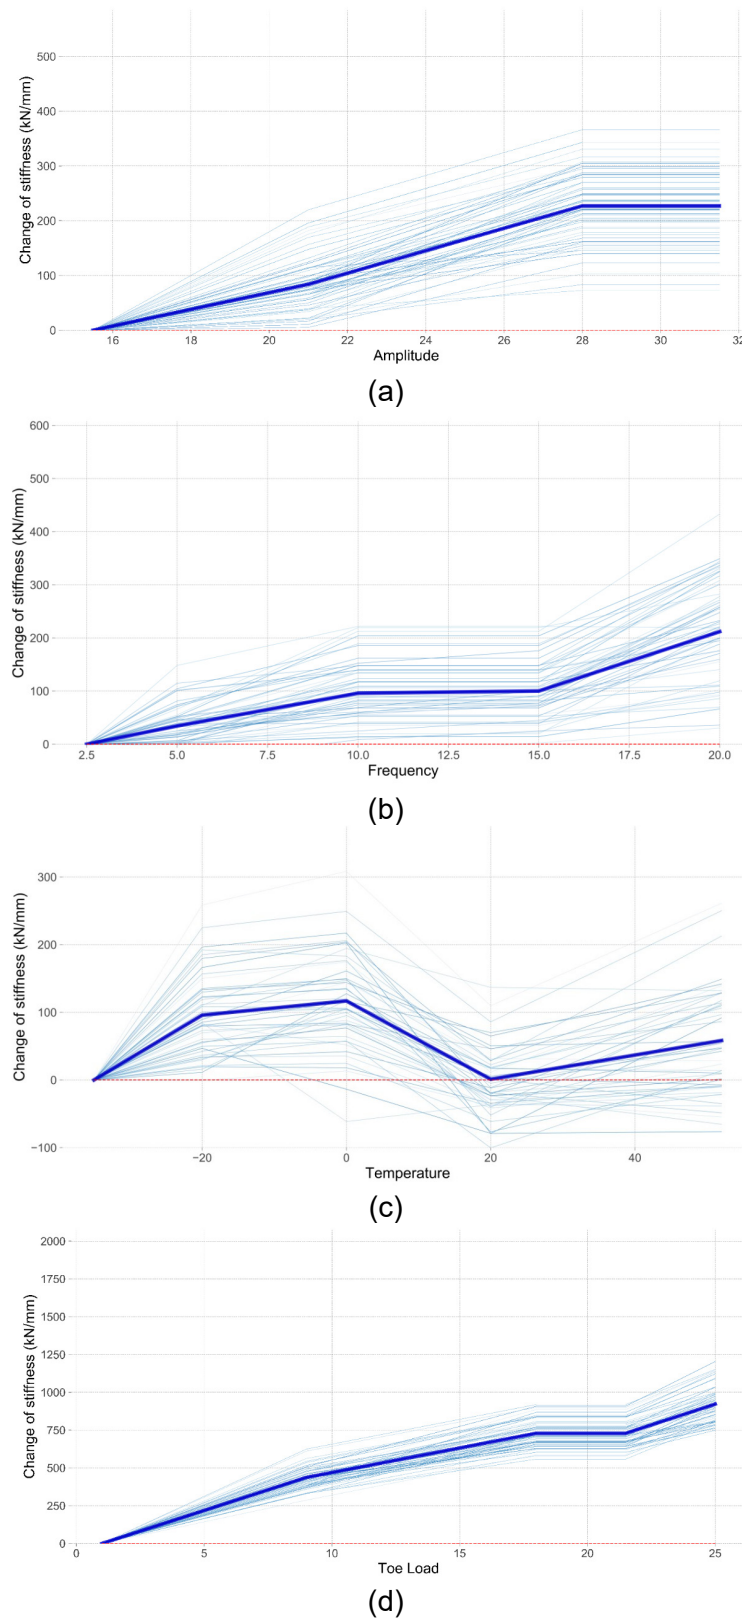


Figura 4-17: Partial dependence plots de la placa de asiento de EVA.

CAPÍTULO 5

Conclusiones y trabajo futuro

En el presente capítulo, se resumen las principales conclusiones alcanzadas a partir de los trabajos desarrollados en este trabajo fin de master, recordando que el objetivo principal del mismo consiste en identificar las variables que afectan a la rigidez dinámica vertical de las placas de asiento fabricadas en EPDM, TPE y EPDM y el grado de influencia de cada una de ellas. De manera adicional, se han generado tres modelos, uno por material, capaces de estimar las propiedades mecánicas de las placas de asiento en función de los parámetros de ensayo.

5.1 Conclusiones

5.1.1 Ensayos convencionales

- El aumento de la temperatura (en el rango entre -35°C y 52°C) provoca una reducción de la rigidez estática y dinámica independientemente del material analizado. Este patrón de comportamiento es esperable en materiales poliméricos. Sin embargo, las variaciones específicas de la rigidez dependen en gran medida del material. Fijando el resto de las variables a sus valores estándar de alta velocidad, los cambios de rigidez sufridos por el EPDM, TPE y EVA al disminuir la temperatura de 52°C a -35°C son, respectivamente, 437%, 173% y 11% de la rigidez a la temperatura máxima (52°C). Estos resultados muestran la alta sensibilidad a la variación térmica, especialmente de EPDM y TPE. Se ha comprobado que la temperatura influye poco en el EPDM cuando la temperatura es superior a -10°C , momento en el que la placa comienza a rigidizarse rápidamente. El TPE, por otro lado, muestra una variación uniforme en la rigidez dinámica a medida que varía la temperatura. Finalmente, el EVA muestra un comportamiento termoestable.
- Se ha observado que el aumento de la carga por eje (amplitud entre 15,5 y 31,5 kN) viene acompañada sistemáticamente de un aumento de las rigideces estáticas y dinámicas. Sin embargo, cada uno de los materiales muestra un nivel específico de sensibilidad a esta influencia. Las variaciones entre los valores máximos y mínimos de rigidez dinámica, tomando estos últimos como referencia y fijando el resto de las variables a sus valores estándar para condiciones de alta velocidad, son del 53%, 3% y 11% para el EPDM, TPE y EVA, respectivamente. En este caso, el caso el EPDM es el más sensible a las variaciones de carga.

- El toe load aplicado a las placas de asiento ha variado entre 1 y 25 kN. En este escenario, todos los materiales han sufrido aumentos de rigidez, tanto estática como dinámica, después de aumentar el toe load. Las variaciones observadas en la rigidez dinámica dependen en gran medida del material. Así, los cambios medidos entre los valores de rigidez máxima y mínima, respecto al mínimo, son del 159% para el EPDM, del 42% para el TPE y del 126% para el EVA. En estas comparaciones, los valores del resto de las variables se han fijado en sus valores estándar para la alta velocidad.
- La influencia de la frecuencia, en el rango entre 2,5 Hz y 20 Hz, sobre la rigidez dinámica de los tres materiales, ha dado resultados similares. Sistemáticamente, a medida que aumenta la frecuencia, las placas de asiento se vuelven más rígidas. Las variaciones de rigidez observadas, referidas al valor mínimo, son similares: 24% para EPDM, 19% para TPE y 34% para EVA. Como en los casos anteriores, la comparación se ha realizado fijando el resto de parámetros a sus valores de referencia de alta velocidad. También se puede ver que en todos los casos la rigidez dinámica es mayor que la rigidez estática.

5.1.2 Machine learning

- Las placas de asiento están fabricadas en materiales no solamente altamente no lineales; además, las variables que influyen sobre las propiedades mecánicas interactúan entre sí. Por ello, resulta impracticable desarrollar un modelo capaz de predecir las propiedades de las placas de asiento de una manera tradicional. Por esto se propone la utilización de algoritmos machine learning para el modelado de la rigidez de las placas.
- Se destaca la buena correlación encontrada entre los resultados obtenidos mediante ensayos de laboratorio y los resultados proporcionados por los algoritmos de machine learning especialmente los algoritmos random forest y multilayer perceptron.

- Se ha demostrado que los resultados obtenidos tanto mediante el análisis convencional como mediante el análisis mediante machine learning son concordantes, ya que a través de ambos métodos se han identificado los mismos parámetros como parámetros críticos en la rigidez vertical de las placas de asiento.
- En el caso del EPDM, los parámetros que tienen mayor influencia en la rigidez vertical dinámica son la temperatura y el toe load. En el caso de la temperatura, la influencia es pequeña siempre que la se encuentre por encima de los -10°C , momento a partir del cual la placa de asiento sufre una fuerte rigidización.
- Se ha determinado que, para el TPE, los parámetros que tienen mayor influencia en la rigidez vertical dinámica son la temperatura y el toe load.
- El parámetro que tiene mayor influencia en la rigidez vertical dinámica de la placa fabricada en EVA es el toe load, especialmente cuando este es pequeño, ya que para valores de toe load pequeños la placa recibe deformaciones notablemente mayores que cuando ya tiene una cierta precarga de aproximadamente 10 kN.
- Se ha demostrado tanto mediante el análisis convencional como por el análisis de machine learning que, en los tres casos, resulta más influyente las condiciones en las que está trabajando la placa de asiento (temperatura y toe load) que el tipo de vehículo que circula por la vía (amplitud y frecuencia).
- Es posible predecir de manera extremadamente precisa la rigidez de las placas de asiento en función de las condiciones de uso a través de algoritmos de machine learning. Estos algoritmos pueden utilizarse para definir unas propiedades mecánicas equivalentes que permitan convertir modelos sumamente complejos en modelos elástico lineales.

5.1 Trabajo futuro

Se proponen las siguientes líneas de investigación derivadas del presente trabajo fin de master:

- Dado que uno de los puntos débiles de los modelos computacionales para analizar el comportamiento de la vía es la dificultad de definir las propiedades mecánicas tanto de la sujeción como del balasto, se propone combinar un modelo de machine learning con un modelo de elementos finitos. El primero proporcionará al segundo unas propiedades mecánicas equivalentes en función de las condiciones de carga aplicadas.
- Analizar la influencia de los parámetros de fabricación de las placas de asiento sobre sus propiedades mecánicas. Concretamente, se plantea el objetivo de definir un algoritmo capaz de estimar los parámetros de fabricación a partir de un valor de rigidez buscado.
- Se plantea analizar la influencia que tiene sobre la rigidez vertical, tanto estática como dinámica, la geometría de la placa de asiento, esto engloba analizar tanto si se trata de una placa maciza como aligerada, tipos de aligeramiento o espesor de la placa.
- Se plantea realizar un estudio similar al realizado con la rigidez vertical dinámica, pero analizando cómo afectan cada una de estas variables al amortiguamiento de la placa.

CAPÍTULO 6

Bibliografía

- [1] G. de E. Ministerio de Fomento, Informe anual del Observatorio del Transporte y la Logística en España, n.d.
<http://observatoriotransporte.fomento.es/NR/rdonlyres/EE4D9E3E-74A9-4C1F-A5FC-284D30BBAFFA/148831/INFORMEOTLE2017.pdf>
(accessed August 10, 2019).
- [2] G. de E. Ministerio de Fomento, Informe de la Comisión técnico-científica para el estudio de mejoras en el sector ferroviario, n.d.
https://www.fomento.gob.es/recursos_mfom/informecomisiontecnicocientificasectorferroviario1.pdf (accessed August 11, 2019).
- [3] K. Nguyen, J.M. Goicolea, F. Galbadon, Dynamic effect of high speed railway traffic loads on the ballast track settlement, Congr. Métodos Numéricos Em Eng. (2011).

- [4] N. Bosso, A. Gugliotta, N. Zampieri, A Comprehensive Strategy to Estimate Track Condition and its Evolution, *Int. J. Railw. Technol.* 1 (2012) 1–19. doi:10.4203/ijrt.1.2.1.
- [5] B. Indraratna, S. Nimbalkar, C. Rujikiatkamjorn, Modernisation of Rail Tracks for Higher Speeds and Greater Freight, *Int. J. Railw. Technol.* 2 (2013) 1–20. doi:10.4203/ijrt.2.3.1.
- [6] E. Fortunato, A. Paixão, R. Calçada, Railway Track Transition Zones: Design, Construction, Monitoring and Numerical Modelling, *Int. J. Railw. Technol.* 2 (2013) 33–58. doi:10.4203/ijrt.2.4.3.
- [7] S.B. Mezher, D.P. Connolly, P.K. Woodward, O. Laghrouche, J. Pombo, P.A. Costa, Railway critical velocity – Analytical prediction and analysis, *Transp. Geotech.* 6 (2016) 84–96. doi:10.1016/j.trgeo.2015.09.002.
- [8] Y. Momoya, T. Nakamura, S. Fuchigami, T. Takahashi, Improvement of Degraded Ballasted Track to Reduce Maintenance Work, *Int. J. Railw. Technol.* 5 (2016) 31–54. doi:10.4203/ijrt.5.3.2.
- [9] P.K. Woodward, O. Laghrouche, S.B. Mezher, D.P. Connolly, Application of Coupled Train-Track Modelling of Critical Speeds for High-Speed Trains using Three-Dimensional Non-Linear Finite Elements, *Int. J. Railw. Technol.* 4 (2015) 1–35. doi:10.4203/ijrt.4.3.1.
- [10] S. Muñoz, J.F. Aceituno, P. Urda, J.L. Escalona, Multibody model of railway vehicles with weakly coupled vertical and lateral dynamics, *Mech. Syst. Signal Process.* 115 (2019) 570–592. doi:10.1016/j.ymssp.2018.06.019.
- [11] J. Pombo, J. Ambrósio, M. Silva, A new wheel–rail contact model for railway dynamics, *Veh. Syst. Dyn.* 45 (2007) 165–189. doi:10.1080/00423110600996017.
- [12] A. Alonso, A. Guiral, J.G. Gimenez, Wheel Rail Contact: Theoretical and Experimental Analysis, *Int. J. Railw. Technol.* 2 (2013) 15–32. doi:10.4203/ijrt.2.4.2.

- [13] J. Pombo, J. Ambrósio, Application of a wheel–rail contact model to railway dynamics in small radius curved tracks, *Multibody Syst. Dyn.* 19 (2008) 91–114. doi:10.1007/s11044-007-9094-y.
- [14] M.S. Sichani, R. Enblom, M. Berg, Non-Elliptic Wheel-Rail Contact Modelling in Vehicle Dynamics Simulation, *Int. J. Railw. Technol.* 3 (2014) 77–96. doi:10.4203/ijrt.3.3.5.
- [15] H. Magalhães, F. Marques, B. Liu, P. Antunes, J. Pombo, P. Flores, J. Ambrósio, J. Piotrowski, S. Bruni, Implementation of a non-Hertzian contact model for railway dynamic application, *Multibody Syst. Dyn.* (2019). doi:10.1007/s11044-019-09688-y.
- [16] F. Marques, H. Magalhães, B. Liu, J. Pombo, P. Flores, J. Ambrósio, J. Piotrowski, S. Bruni, On the generation of enhanced lookup tables for wheel-rail contact models, *Wear.* 434–435 (2019) 202993. doi:10.1016/j.wear.2019.202993.
- [17] E.A.H. Vollebregt, M.J.M.M. Steenbergen, A Methodology for Assessing Track Irregularities with respect to Rail Damage, *Int. J. Railw. Technol.* 4 (2015) 85–105. doi:10.4203/ijrt.4.4.5.
- [18] J. Pombo, J. Ambrósio, An alternative method to include track irregularities in railway vehicle dynamic analyses, *Nonlinear Dyn.* 68 (2012) 161–176. doi:10.1007/s11071-011-0212-2.
- [19] S.S. Hsu, N. Fagan, Improving Switches and Crossings Performance and Reliability, *Int. J. Railw. Technol.* 5 (2016) 79–93. doi:10.4203/ijrt.5.3.4.
- [20] I. Coleman, E. Kassa, R. Smith, Wheel-Rail Contact Modelling within Switches and Crossings, *Int. J. Railw. Technol.* 1 (2012) 45–66. doi:10.4203/ijrt.1.2.3.
- [21] P. Hölscher, The Dynamics of Foundations for High Speed Lines on Soft Soils, *Int. J. Railw. Technol.* 1 (2012) 147–166. doi:10.4203/ijrt.1.1.7.

- [22] R. Sañudo, V. Markine, J. Pombo, Study on Different Solutions to Reduce the Dynamic Impacts in Transition Zones for High-Speed Rail, *J. Theor. Appl. Vib. Acoust.* 3 (2017) 199–222. doi:10.22064/tava.2018.80091.1095.
- [23] S.D. Iwnicki, A.J. Bevan, Damage to Railway Wheels and Rails: A Review of the Causes, Prediction Methods, Reduction and Allocation of Costs, *Int. J. Railw. Technol.* 1 (2012) 121–146. doi:10.4203/ijrt.1.1.6.
- [24] S. Stichel, P.-A. Jönsson, C. Casanueva, S. Hossein Nia, Modelling and Simulation of Freight Wagon with Special attention to the Prediction of Track Damage, *Int. J. Railw. Technol.* 3 (2014) 1–36. doi:10.4203/ijrt.3.1.1.
- [25] N. Kuka, R. Verardi, C. Ariaudo, J. Pombo, Impact of maintenance conditions of vehicle components on the vehicle–track interaction loads, *Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci.* 232 (2018) 2626–2641. doi:10.1177/0954406217722803.
- [26] Andrés López-Pita, *Infraestructuras ferroviarias*, EDICIONES UPC, 2006.
- [27] T.L.E. Dahlberg, On the use of under-sleeper pads in tracks with varying track stiffness, in: *Proc. - 9th Int. Heavy Haul Conf. "Heavy Haul Innov. Dev.*, 2009.
- [28] P.F. Teixeira, F. Robuste, A. Lo, High speed and track deterioration : the role of vertical stiffness of the track, *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit.* 218 (2004) 31–40. doi:10.1243/095440904322804411.
- [29] J. Sainz-Aja, I. Carrascal, J.A. Polanco, C. Thomas, I. Sosa, J. Casado, S. Diego, Self-compacting recycled aggregate concrete using out-of-service railway superstructure wastes, *J. Clean. Prod.* 230 (2019). doi:10.1016/j.jclepro.2019.04.386.
- [30] M. Sol-Sánchez, F. Moreno-Navarro, M.C. Rubio-Gámez, The use of elastic elements in railway tracks: A state of the art review, *Constr. Build. Mater.* 75 (2015) 293–305. doi:10.1016/J.CONBUILDMAT.2014.11.027.

- [31] D. Ferreño, J.A.J.A. Casado, I.A.I.A. Carrascal, S. Diego, E. Ruiz, M. Saiz, J.A.J.A. Sainz-Aja, A.I.A.I. Cimentada, Experimental and finite element fatigue assessment of the spring clip of the SKL-1 railway fastening system, *Eng. Struct.* 188 (2019) 553–563. <https://www.sciencedirect.com/science/article/pii/S014102961832618X?via%3Dihub> (accessed April 6, 2019).
- [32] S. Kaewunruen, A.M. Remennikov, Sensitivity analysis of free vibration characteristics of an in situ railway concrete sleeper to variations of rail pad parameters, *J. Sound Vib.* 298 (2006). doi:10.1016/j.jsv.2006.05.034.
- [33] A. Fenander, Frequency dependent stiffness and damping of railpads, *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit.* 211 (1997) 51–62. doi:10.1243/0954409971530897.
- [34] K. Wei, P. Wang, F. Yang, J. Xiao, Influence of frequency-dependent dynamic parameters of rail pads on environmental vibration induced by subways in a tunnel, 2015. doi:10.1037/a0034953.
- [35] S. Kaewunruen, A.M. Remennikov, Response and Prediction of Dynamic Characteristics of Worn Rail Pads Under Static Preloads, *Univ. Wollongong.* (2007) 9–12.
- [36] S. Kaewunruen, A.M. Remennikov, Laboratory Measurements of Dynamic Properties of Rail Pads under Incremental Preload, 19th Australas. Conf. Mech. Struct. Mater. (2007) 319–324.
- [37] S.Y. Zhu, C.B. Cai, Z. Luo, Z.Q. Liao, A frequency and amplitude dependent model of rail pads for the dynamic analysis of train-track interaction, *Sci. China Technol. Sci.* (2014). doi:10.1007/s11431-014-5686-y.
- [38] K. Wei, P. Zhang, P. Wang, J. Xiao, Z. Luo, The influence of amplitude- and frequency-dependent stiffness of rail pads on the random vibration of a vehicle-track coupled system, *Shock Vib.* (2016). doi:10.1155/2016/7674124.

- [39] K. Wei, F. Wang, P. Wang, Z.X. Liu, P. Zhang, Effect of temperature- and frequency-dependent dynamic properties of rail pads on high-speed vehicle-track coupled vibrations, *Veh. Syst. Dyn.* 55 (2017) 351–370. doi:10.1080/00423114.2016.1267371.
- [40] UNE-EN 13481-2:2012+A1:2017. Aplicaciones ferroviarias. Vía. Requisitos de funcionamiento para los conjuntos de sujeción. Parte 2: Conjuntos de sujeción para las traviesas de hormigón., in: 2017.
- [41] EN 13146-9:2011+A1. Aplicaciones ferroviarias. Vía. Métodos de ensayo de los sistemas de fijación. Parte 9: Dterminación de la rigidez., in: 2012.
- [42] K. Wei, P. Zhang, P. Wang, J. Xiao, Z. Luo, The Influence of Amplitude- and Frequency-Dependent Stiffness of Rail Pads on the Random Vibration of a Vehicle-Track Coupled System, *Hindawi Publ. Corp. Shock Vib.* (n.d.). doi:http://dx.doi.org/10.1155/2016/7674124.
- [43] K. Wei, F. Wang, P. Wang, Z.X. Liu, P. Zhang, Effect of temperature- and frequency-dependent dynamic properties of rail pads on high-speed vehicle-track coupled vibrations, *Veh. Syst. Dyn.* 55 (2017) 351–370. doi:10.1080/00423114.2016.1267371.
- [44] U. Özdemir, B. Özbay, S. Veli, S. Zor, Modeling adsorption of sodium dodecyl benzene sulfonate (SDBS) onto polyaniline (PANI) by using multi linear regression and artificial neural networks, *Chem. Eng. J.* 178 (2011) 183–190.
- [45] S. Asadi, S.S. Amiri, M. Mottahedi, On the development of multi-linear regression analysis to assess energy consumption in the early stages of building design, *Energy Build.* 85 (2014) 246–255.
- [46] L. Zhang, Q. Liu, W. Yang, N. Wei, D. Dong, An improved k-nearest neighbor model for short-term traffic flow prediction, *Procedia-Social Behav. Sci.* 96 (2013) 653–662.

- [47] C. Hu, G. Jain, P. Zhang, C. Schmidt, P. Gomadam, T. Gorka, Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery, *Appl. Energy*. 129 (2014) 49–55.
- [48] M.R. Segal, Regression trees for censored data, *Biometrics*. (1988) 35–47.
- [49] W. Loh, Classification and regression trees, *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.* 1 (2011) 14–23.
- [50] L. Breiman, Random forests, *Mach. Learn.* 45 (2001) 5–32. doi:10.1023/A:1010933404324.
- [51] G.-B. Huang, Q.-Y. Zhu, C.-K. Siew, Extreme learning machine: Theory and applications, *Neurocomputing*. 70 (2006) 489–501. doi:10.1016/J.NEUCOM.2005.12.126.
- [52] D.W. Ruck, S.K. Rogers, M. Kabrisky, M.E. Oxley, B.W. Suter, The multilayer perceptron as an approximation to a Bayes optimal discriminant function, *IEEE Trans. Neural Networks*. 1 (1990) 296–298.
- [53] S.K. Pal, S. Mitra, Multilayer perceptron, fuzzy sets, and classification, *IEEE Trans. Neural Networks*. 3 (1992) 683–697.
- [54] A.J. Smola, B. Schölkopf, A tutorial on support vector regression, *Stat. Comput.* 14 (2004) 199–222.
- [55] H. Drucker, C.J.C. Burges, L. Kaufman, A.J. Smola, V. Vapnik, Support vector regression machines, in: *Adv. Neural Inf. Process. Syst.*, 1997: pp. 155–161.
- [56] Ministerio de fomento, IAP-11 Instrucción sobre las acciones a considerar en el proyecto de puentes de carretera, (2012).
- [57] J.H. Friedman, Greedy function approximation: a gradient boosting machine, *Ann. Stat.* (2001) 1189–1232.

- [58] I.A. Carrascal, A. Pérez, J.A. Casado, S. Diego, J.A. Polanco, D. Ferreño, J.J. Martín, Experimental study of metal cushion pads for high speed railways, *Constr. Build. Mater.* 182 (2018) 273–283. doi:10.1016/j.conbuildmat.2018.06.134.
- [59] K. Wei, Z. Liu, Y. Liang, P. Wang, An investigation into the effect of temperature-dependent stiffness of rail pads on vehicle-track coupled vibrations, *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit.* 231 (2017) 444–454. doi:10.1177/0954409716631786.